

UNIVERZITA KARLOVA

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Tomáš Kuthan

**KLASIFIKACE VYBRANÝCH ZEMĚDĚLSKÝCH PLODIN
V MODELOVÉM ÚZEMÍ KUTNOHORSKA S VYUŽITÍM ČASOVÉ
ŘADY DAT SENTINEL-2 A PLANETSCOPE**

**CLASSIFICATION OF SELECTED AGRICULTURAL CROPS FROM TIME
SERIES OF SENTINEL-2 AND PLANETSCOPE IMAGERY IN KUTNOHORSKO
MODEL AREA**

Diplomová práce

Vedoucí diplomové práce: RNDr. Lucie Kupková, Ph.D.

Konzultanti: Mgr. Lucie Červená

Mgr. Renata Suchá

Mgr. Zuzana Žáková

Praha 2018

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 7. 12. 2018

.....

podpis

Poděkování

Rád bych na tomto místě poděkoval RNDr. Lucii Kupkové za odborné vedení mé diplomové práce a dále také za věnovaný čas a odborné rady a připomínky. Dále bych chtěl poděkovat Mgr. Renatě Suché a Mgr. Zuzaně Žákové za konzultace týkající se problematiky zemědělských ploch v České republice. Také bych rád poděkoval Mgr. Renatě Bodnárové a Ing. Ludmile Hejdánkové za poskytnutí informací a dat k zemědělským plodinám od zemědělských družstev PIAS a.s. Suchdol, ZOD Úmonín, Agro Kluky s.r.o. a ZOS Kačina a.s. Mé poděkování patří též společnosti Planet.com za poskytnutí družicových dat PlanetScope a programu Copernicus.eu za poskytnutí družicových dat Sentinel-2.

Klasifikace vybraných zemědělských plodin v modelovém území Kutnohorska s využitím časové řady dat Sentinel-2 a PlanetScope

Abstrakt

Práce je zaměřena na analýzu spektrálních charakteristik vybraných zemědělských plodin v průběhu zemědělské sezóny z časové řady družicových dat senzorů Sentinel-2 (A a B) a PlanetScope v modelovém území v okolí sídel Kolín a Kutná Hora. Vychází z předpokladu, že využití více termínů obrazových dat, která zachycují plodiny v různých fenologických fázích, umožňuje lepší identifikaci druhů plodin (Lu et al., 2004). Cílem práce bylo zpracovat charakteristiku sezónního průběhu spektrálních příznaků vybraných zemědělských plodin (cukrovka, ječmen jarní, ječmen ozimý, kukuřice, pšenice jarní, pšenice ozimá, řepka ozimá), která určí období roku vhodná pro odlišení jednotlivých plodin. Dalším cílem práce bylo provést klasifikaci těchto plodin v modelovém území z časové řady dat dvou výše zmíněných senzorů a porovnat přesnost pixelové a objektově orientované klasifikace pro multitemporální kompozit a přesnost pro snímek z období, kdy jsou od sebe jednotlivé plodiny dobře rozlišitelné. Trénovací a validační plochy a klasifikační maska byly vytvořeny s využitím databáze LPIS, kterou poskytl Státní zemědělský intervenční fond. Pro klasifikaci byla využita časová řada družicových dat obou senzorů z roku 2017. Využita byla i data z let 2015 a 2016 z databáze LPIS pro zjištění spektrálních příznaků plodin, které byly určeny z indexu NDVI a spektrálních hodnot v jednotlivých pásmech. Nejvyšší celkové přesnosti (88,4 %) bylo dosaženo pixelovou klasifikací (klasifikátorem maximální pravděpodobnosti) multitemporálního kompozitu dat Sentinel-2A a 2B (tvořeného šesti scénami o deseti pásmech), nejlepší objektová klasifikace (též z dat multitemporálního kompozitu Sentinelu-2A, B; 6 scén; 24 pásem – RGB, NIR) dosáhla celkové přesnosti 87,29 %. Nejvyšší celkové přesnosti v rámci klasifikace monotemporálním přístupem (76,19 %) bylo dosaženo ze snímku Sentinelu-2 z termínu 20. 6. 2017. Potvrdil se tedy předpoklad, že využití multitemporálního kompozitu přináší významně přesnější výsledky pro klasifikaci zmíněných plodin. U dat Sentinelu-2 byl prokázán vliv pásem RED EDGE a SWIR na zvýšení přesnosti pixelové klasifikace. Větší prostorové rozlišení dat PlanetScope nepřineslo oproti předpokladu lepší klasifikační výsledky ve srovnání s daty Sentinelu-2, který disponuje lepším spektrálním rozlišením.

Klíčová slova: časová řada družicových dat, zemědělské plodiny, klasifikace, spektrální příznak, Sentinel-2, PlanetScope

Classification of selected agricultural crops from time series of Sentinel-2 and PlanetScope imagery in Kutnohorsko model area

Abstract

The thesis is focused on the analysis of spectral characteristics of selected agricultural crops during agricultural season from time series of Sentinel-2 (A and B) and PlanetScope sensors in the model area situated around the settlements of Kolín and Kutná Hora. It is based on the assumption that the use of multiple dates of image data acquired crops in different phenological phases of the crops allows better identification of crop species (Lu et al., 2004). The aim of the thesis was to analyse the characteristics of the seasonal course of spectral features of selected agricultural crops (sugar beet, spring barley, winter barley, maize, spring wheat, winter wheat, winter rape) and to determine the period of the year suitable for the differentiation of individual crops. Another aim of the thesis was to classify these crops in the model area from time series of two above-mentioned sensors and to compare the accuracy of the pixel and object-oriented classification approach for multitemporal composites and the accuracy for monotemporal image from the term when the individual crops are clearly distinguishable. The training and validation datasets and the classification mask were created using LPIS database provided by the State Agricultural Intervention Fund. The time of satellite data of the both sensors from 2017 were used for the classification. Data from 2015 and 2016 from LPIS database were also used for the detection of the spectral features of crops, that were determined from the NDVI and the from spectral values in the individual bands. The highest overall accuracy (88,4 %) was achieved by the pixel classification (maximum likelihood classifier) of the 1st multitemporal composite created from Sentinel-2A and 2B data (consisting of six ten-band scenes). The best object based classification (from Sentinel-2A and 2B 2nd multitemporal composite: 6 scenes, 24 bands - RGB, NIR) achieved a total accuracy of 87,29 %. The highest overall accuracy within the monotemporal approach classification (76,19 %) was obtained from the Sentinel-2 image acquired in 20 June 2017. Therefore, the assumption that the use of the multitemporal composite yields significantly more accurate results for the classification of the agricultural crops has been confirmed. The significance of the RED EDGE and SWIR bands of Sentinel-2 for the accuracy improvement of the pixel classification was documented. Higher spatial resolution of PlanetScope data did not bring better classification results compared to Sentinel-2 data, that has better spectral resolution.

Keywords: time series of satellite imagery, agricultural crops, classification, spectral feature, Sentinel-2, PlanetScope

Zadání diplomové práce

pro Tomáš Kuthana

obor Kartografie a geoinformatika

Název tématu: Klasifikace vybraných zemědělských plodin v modelovém území
Kutnohorska s využitím časové řady dat Sentinel-2 a PlanetScope

Zásady pro vypracování

Diplomová práce se zaměří na analýzu spektrálních charakteristik vybraných zemědělských plodin v průběhu zemědělské sezóny z časové řady dat Sentinel-2 a PlanetScope. Mezi vybrané plodiny patří: cukrovka, ječmen jarní, ječmen ozimý, kukuřice, pšenice ozimá, řepka ozimá, oves, vojtěška, trvalé travní porosty a úhor. Všechny tyto typy ploch jsou uloženy v geoprostorové databázi LPIS, která je spravována Státním zemědělským a intervenčním fondem, který poskytne data pro modelové území Kutnohorska. Cílem práce bude zpracovat charakteristiku sezónního průběhu spektrálních příznaků plodin, která určí období roku vhodná pro odlišení jednotlivých plodin. Dalším cílem práce je provést klasifikaci těchto plodin v modelovém území z časové řady dat dvou výše zmíněných senzorů a porovnat přesnost pixelové a objektově orientované klasifikace pro multitemporální kompozit, případně pro snímek z období, kdy jsou od sebe jednotlivé plodiny dobře rozlišitelné. Cílem práce je také porovnat přesnost klasifikace při použití dvou typů dat s rozdílným prostorovým a spektrálním rozlišením.

Rozsah grafických prací: dle potřeby

Rozsah průvodní zprávy: cca 80 stran

Seznam odborné literatury:

SOLA, I. et al., 2018. Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes. *International Journal of Applied Earth Observation and Geoinformation* [online]. 73, str. 63-76. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243418301843>

VUOLO, F. et al., 2018. How much does multi-temporal Sentinel-2 data improve crop type classification?. *International Journal of Applied Earth Observation and Geoinformation* [online]. 72, str. 122-130. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243418303167>

BELGIU, M., CSILLIK, O., 2017. Sentinel-2 cropland mapping using pixel-based and object-based timeweighted dynamic time warping analysis. *Remote Sensing of Environment* [online]. 204, str. 509-523. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0034425717304686>

MORAN, S. M., INOUE, Y., BARNES, M. E., 1997. Opportunities and Limitations for Image-Based Remote Sensing in Precision Crop Management. *Remote Sensing of Environment* [online]. 61(3), str. 319-346. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S003442579700045X>

BUNNIK, J. J. N., 1981. Spectral reflectance characteristics of agriculture crops and application to crop growth monitoring. *Advances in Space Research* [online]. 1(10), str. 21-40. Dostupné z: <https://www.sciencedirect.com/science/article/pii/0273117781903793>

MANGIAROTTI, S. et al., 2017. Can the global modeling technique be used for crop classification?. *Chaos, Solitons & Fractals* [online]. 106, str. 363-378. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0960077917305040>

SCHOWENGERDT, A. R., 2007. Remote Sensing: Models and methods for image processing. 3. vyd. Tuscon: University of Arizona. 515 str. ISBN 10: 0-12-369407-8.

Vedoucí diplomové práce: RNDr. Lucie Kupková, Ph.D.

Konzultant diplomové práce: Mgr. Lucie Červená
Mgr. Renata Suchá
Mgr. Zuzana Žáková

Datum zadání diplomové práce: prosinec 2017

Termín odevzdání diplomové práce: prosinec 2018

.....
Vedoucí diplomové práce

.....
Vedoucí katedry

V Praze dne 11. 8. 2018

OBSAH

OBSAH.....	8
SEZNAM OBRÁZKŮ.....	10
SEZNAM TABULEK	10
SEZNAM GRAFŮ.....	11
SEZNAM POUŽITÝCH ZKRATEK.....	12
1. ÚVOD A CÍLE PRÁCE	15
2. REŠERŠE A ÚVOD DO PROBLEMATIKY	17
2.1. Korekce dat	17
2.2. PCA.....	18
2.3. Vegetační index NDVI	19
2.4. Klasifikace	19
2.4.1. Pixelová klasifikace.....	20
2.4.1.1. Klasifikátor maximální pravděpodobnosti.....	20
2.4.1.2. Support vector machines classifier (SVM)	21
2.4.2. Objektová klasifikace	22
2.4.2.1. Segmentace obrazu a její metody.....	22
2.4.3. Multitemporální přístup ke klasifikaci plodin	23
2.4.4. Hodnocení přesnosti klasifikace.....	25
2.5. Fenologie plodin	26
2.5.1. Ozim	26
2.5.2. Jařina	26
2.5.3. Vegetační fáze plodin.....	26
2.6. Metody klasifikace pro mapování zemědělských plodin.....	31
3. MODELOVÉ ÚZEMÍ	38
4. DATA	40
4.1. Data Sentinel-2.....	40
4.2. Data PlanetScope	42
4.3. Ostatní datové zdroje	43
5. METODIKA.....	44
5.1. Předzpracování dat.....	44
5.1.1. Atmosférické a radiometrické korekce.....	44
5.1.1.1. Sen2Cor.....	44
5.1.2. Převzorkování, konverze a ořez dat	45

5.1.3.	Tvorba legendy.....	45
5.1.3.1.	Cukrovka.....	46
5.1.3.2.	Ječmen jarní a ječmen ozimý	46
5.1.3.3.	Kukuřice.....	46
5.1.3.4.	Pšenice jarní a pšenice ozimá.....	46
5.1.3.5.	Řepka ozimá.....	47
5.1.3.6.	Travní porost na orné půdě	47
5.1.3.7.	Trvale travní porost.....	47
5.1.3.8.	Úhor	47
5.1.3.9.	Ostatní	48
5.1.4.	Tvorba klasifikační masky	48
5.1.5.	Tvorba trénovacích a validačních datasetů	49
5.2.	Analýza dat	52
5.2.1.	Analýzy spektrálních příznaků.....	52
5.2.2.	Klasifikace.....	52
5.2.2.1.	Pixelová klasifikace	53
5.2.2.2.	Objektová klasifikace.....	54
5.3.	Validace dat	55
5.4.	Použitý Software	55
5.4.1.	SNAP.....	55
5.4.2.	ENVI	55
5.4.3.	ArcGIS for Desktop	55
6.	VÝSLEDKY	57
6.1.	Analýzy spektrálních příznaků klasifikačních tříd	57
6.1.1.	Obecné znaky tříd.....	58
6.1.2.	Cukrovka	59
6.1.3.	Ječmen jarní.....	60
6.1.4.	Ječmen ozimý.....	61
6.1.5.	Kukuřice	62
6.1.6.	Pšenice jarní	63
6.1.7.	Pšenice ozimá	64
6.1.8.	Řepka ozimá	65
6.1.9.	Trávy	66
6.1.10.	Srovnání NDVI hodnot pro S-2 a PS.....	66
6.1.11.	Spektrální hodnoty v pásmech S-2	68
6.1.12.	Kombinované spektrální grafy z let 2015 až 2017	71
6.2.	Fenofáze jednotlivých tříd (plodin).....	74
6.3.	Výsledky klasifikací.....	76
6.3.1.	Celkové přesnosti pixelové klasifikace	76
6.3.1.1.	Vyhodnocení přesnosti multitemporálního přístupu pro jednotlivé třídy	77
6.3.1.2.	Vyhodnocení přesnosti monotemporálního přístupu pro jednotlivé třídy ..	78

6.3.2.	Objektová klasifikace	79
6.3.3.	Porovnání pixelové a objektové klasifikace	80
6.4.	Výsledky klasifikací vs. skutečný stav z LPIS	81
6.5.	Mapové výstupy	83
7.	DISKUZE.....	89
8.	ZÁVĚR.....	98
	POUŽITÉ ZDROJE INFORMACÍ.....	100
	POUŽITÉ DATOVÉ ZDROJE.....	104
	SEZNAM PŘÍLOH	106

SEZNAM OBRÁZKŮ

Obr. 1:	Schéma metod používaných k atmosférické korekci	18
Obr. 2:	Ukázka vysoké a nízké separability tříd ve dvourozměrném prostoru	19
Obr. 3:	Schéma přiřazování pixelů dle klasifikátorů.....	20
Obr. 4:	Princip možnosti lineárního oddělení dvou tříd s nelineárními hranicemi pomocí přidané dimenze	21
Obr. 5:	Chessboard segmentation.....	22
Obr. 6:	Princip segmentace pomocí metody quad tree segmentation	23
Obr. 7:	Rozdělení obrazu pomocí metody multiresolution segmentation.....	23
Obr. 8:	Hodnocení klasifikace pomocí chybové matice.....	25
Obr. 9:	Životní cyklus pšenice ozimé, kukuřice a cukrovky.....	27
Obr. 10:	Spektrální projevy NDVI pšenice ozimé, ječmene ozimy a kukuřice	27
Obr. 11:	Porovnání fenofází jednotlivých plodin.....	28
Obr. 12:	Fenologické fáze pšenice ozimé a kukuřice.....	28
Obr. 13:	Temporální příznaky plodin pomocí indexu NDVI ve dvou testovacích územích....	29
Obr. 14:	Fenofáze jednotlivých plodin v průběhu roku	29
Obr. 15:	Diagram plodin ke klasifikaci	30
Obr. 16:	Klasifikační třídy a počet jejich trénovacích a validačních ploch	32
Obr. 17:	Ukázka fenologických etap pro plodiny a travnaté porosty.....	33
Obr. 18:	Mapa modelového území	38
Obr. 19:	Družice Sentinel 2-A.....	40
Obr. 20:	Nastavení modul Sen2Cor	44
Obr. 21:	Rozmístění trénovacích ploch pro pixelovou klasifikaci S-2	50
Obr. 22:	Segmentace při objektové klasifikaci s danými parametry, v L S-2, v P PS	54

SEZNAM TABULEK

Tab. 1:	Spektrální pásma družice Sentinel-2A a jejich rozlišení	41
Tab. 2:	Využité termíny scén S-2.....	42
Tab. 3:	Spektrální pásma družice PlanetScope	42
Tab. 4:	Využité termíny scén PS	43
Tab. 5:	Množství spektrální informace prvních 4 komponent PCA	45
Tab. 6:	Kategorie legendy	45
Tab. 7:	Datasey využité ke klasifikaci	48

Tab. 8: Počty trénovacích ploch a jejich pixelů pro pixelovou klasifikaci	49
Tab. 9: Vyhodnocení míry separability pro trénovací množiny pro S-2 a PS.....	50
Tab. 10: Počty validačních ploch a počty jejich pixelů – pixelová klasifikace.....	51
Tab. 11: Počty trénovací a validační plochy pro objektovou klasifikaci	51
Tab. 12: Porovnání fenofází pro data S-2 a PS	75
Tab. 13: Nejlepší výsledky pixelové klasifikace pro každý dataset.....	76
Tab. 14: Porovnání pixelové klasifikace 1. a 2. multitemporálního datasetu S-2.....	77
Tab. 15: Porovnání přesnosti pixelové klasifikace 1. multitemporálního datasetu S-2 a multitemporálního datasetu PS.....	78
Tab. 16: Srovnání přesnosti klasifikace dvou nejlepších monotemporálních pixelových klasifikací pro S-2 a PS	79
Tab. 17: Nejlepší výsledky objektové klasifikace pro každý dataset.....	79
Tab. 18: Porovnání přesností objektové klasifikace 2. multitemporálního datasetu S-2 a multitemporálního datasetu PS.....	80
Tab. 19: Nejvyšší celkové přesnosti pixelové a objektové klasifikace pro všechny multitemporální datasety	80
Tab. 20: Porovnání nejlepších výsledků pixelové a objektové klasifikace.....	81
Tab. 21: Porovnání rozlohy tříd získaných z jednotlivých klasifikací vůči rozlohám v LPIS (v %)	82
Tab. 22: Termíny odlišitelnosti jednotlivých plodin	94
Tab. 23: Porovnání klasifikačních přesností se zdroji literatury	95
Tab. 24: Přehled všech provedených klasifikací dle celkové přesnosti	106
Tab. 25: Porovnání všech klasifikací monotemporálního přístupu pro data S-2	106
Tab. 26: Porovnání celkových přesností objektové klasifikace obou multitemporálních datasetů S-2	107
Tab. 27: Porovnání pixelové klasifikace 2. multitemporálního datasetu S-2 a multitemporálního datasetu PS.....	107
Tab. 28: Porovnání celkových přesností monotemporálních klasifikací	107

SEZNAM GRAFŮ

Graf 1: Normální rozdělení trénovacích dat reprezentované Gaussovou křivkou	53
Graf 2: Skupina grafů spektrálních projevů a NDVI pro třídu cukrovka.....	59
Graf 3: Skupina grafů spektrálních projevů a NDVI pro ječmen jarní	60
Graf 4: Skupina grafů spektrálních projevů a NDVI pro ječmen ozimý	61
Graf 5: Skupiny grafů spektrálních projevů a NDVI pro třídu kukuřice	62
Graf 6: Skupiny grafů spektrálních projevů a NDVI pro třídu pšenice jarní.....	63
Graf 7: Skupina grafů spektrálních projevů a NDVI pro třídu pšenice ozimá.....	64
Graf 8: Skupina grafů spektrálních projevů a NDVI pro třídu řepka ozimá.....	65
Graf 9: Skupina grafů spektrálních projevů a NDVI pro třídu trávy	66
Graf 10: Porovnání NDVI hodnot pro data S-2 a PS v jednotlivých termínech	68
Graf 11: Spektrální hodnoty pásem jednotlivých tříd pro S-2	70
Graf 12: Kombinovaný graf DN hodnot pro všechny třídy z let 2015, 2016 a 2017.....	72
Graf 13: Kombinovaný graf NDVI hodnot pro všechny třídy z let 2015, 2016 a 2017.....	73
Graf 14: Porovnání rozlohy v procentech pro jednotlivé klasifikace vůči rozlohám v LPIS ..	83

SEZNAM POUŽITÝCH ZKRATEK

BOA	Bottom of Atmosphere
BLUE	modré pásmo viditelného spektra
CDL	Cropland Data Layer
CP	celková přesnost
ČR	Česká republika
DPB	díl půdního bloku
DN	Digital Number
DOS	Dark Object Subtraction
DPZ	Dálkový průzkum Země
EM	elektromagnetický
ENVI	Software pro úpravu dat z DPZ
ESA	European Satellite Agency
ETM+	Enhanced Thematic Mapper
EVI2	Enhanced Vegetation Index 2
FLAASH	Fas Line-of-sight Atmospheric Analysis of Hypercubes
GCC	Greenness Chromatic Coordinate
GIS	geografický informační systém
GNDVI	Green Normalized Difference Vegetation Index
GREEN	zelené pásmo viditelného spektra
iCOR	Atmospheric Image Correction for Land and Water
IRECI	Inverted Red Edge Chlorophyll Index
IRS	Indian Remote Sensing
KNN	K-Nearest Neighbours
LAI	Leaf Area Index
LC	Land Cover
LPIS	Land Parcel Identification System
LU	Land Use
M	maize
MAJA	MACCS ATCOR Joint Algorithm
MCARI	Modified Chlorophyll Absorption Ratio Index
ML	Maximum Likelihood
MSI	Multispectral Instrument
MZe	Ministerstvo zemědělství

NASA	National Aeronautics and Space Administration
NDSBVI	Normalised Differential Short wave-infrared based Vegetation Index
NDRE	Normalized Difference Red Edge Index
NIR	Near Infrared
OBIA	Object-based Image Analysis
PCA	Principal Component Analysis
PHX AMA	Phoenix Active Management Area
PS	PlanetScope
PSP	Phenological Sequence Patterns
PSSRa	Pigment Specific Simple Ratio
RBF	Radial Basis Function
RED	červené pásmo viditelného spektra
RED EDGE	pásmo vlnových délek od 700 do 750 nanometrů
RF	Random Forest
RGB	Red, Green, Blue (pásmo viditelného spektra)
SAVI	Soil-Adjusted Vegetation Index
SB	sugar beet
S-JTSK	souřadnicový systém jednotné trigonometrické sítě katastrální
SL	Super Learner
SVM	Support Vector Machine
SW	software
SWIR	Short-wavelength Infrared
SZIF	Státní zemědělský intervenční fond
S-2	Sentinel-2
TA1	Test Area 1
TA2	Test Area 2
TNDVI	Transformed Normalized Vegetation Index
TOA	Top of Atmosphere
TWDTW	Time-weighted Dynamic Time Warping
UP	uživatelská přesnost
WB	winter barley
WMS	Web Map Service
WR	winter rapessed
WV-2	družice World View 2

WW	winter wheat
ZP	zpracovatelská přesnost
6S	Second Simulation of Satellite Signal in the Solar Spectrum

1. Úvod a cíle práce

Klasifikace a zjišťování spektrálních příznaků zemědělských plodin jsou v oblasti geoinformatiky a dálkového průzkumu dlouhodobě řešenými tématy. Současná data poskytují stále stejná nebo podobná spektrální pásma, jejichž kombinace dosud neumožňují detekovat jednotlivé zemědělské plodiny na zemském povrchu přesně a jednoznačně. Dalším limitujícím faktorem je časové rozlišení dat, které je ve většině případů zcela nedostatečné. Vegetace patří k nejrychleji se měnícím složkám krajiny, a právě proto je obtížné identifikovat příznaky konkrétních plodin. Z toho vyplývá, že je potřeba snímat terén s častým opakováním snímků v průběhu roku s dostatečně vhodným spektrálním rozsahem pásem vhodných pro detekci vegetace, aby byly zachyceny spektrální vlastnosti vegetace ve vhodných termínech, v nichž by byly jednotlivé plodiny oddělitelné.

Data Sentinel-2 či PlanetScope přináší nové možnosti pro klasifikaci zemědělských plodin, jak kvůli svému prostorovému a spektrálnímu rozlišení, tak především z hlediska rozlišení časového. Tyto možnosti by mohly poskytnout lepší možnosti ke zjištění příznaků vybraných plodin v průběhu roku.

Hlavním cílem této práce je analýza spektrálních charakteristik vybraných zemědělských plodin v průběhu zemědělské sezóny z časové řady dat Sentinel-2 a PlanetScope. Mezi vybrané zemědělské plodiny, které tvoří jednotlivé třídy, patří: cukrovka, ječmen jarní, ječmen ozimý, kukuřice, pšenice jarní, pšenice ozimá, řepka ozimá a třída ostatních plodin (vojtěška, oves, úhor, ...). Dále jsou zahrnuty trvale travní porost a trvale travní porost na orné půdě, které dohromady tvoří třídu trávy. Všechny tyto typy ploch jsou obsaženy v geoprostorové databázi LPIS, která je spravována Státním zemědělským a intervenčním fondem (SZIF). Ten poskytl data pro modelové území v oblasti Kutnohorska a Kolínska. Zásadním krokem je zpracovat charakteristiku sezónního průběhu spektrálních příznaků plodin, která určí období roku vhodná pro odlišení jednotlivých plodin. Ke zjištění příznaků se využijí i vegetační indexy.

Dalším cílem práce je provést klasifikaci těchto plodin v modelovém území z časové řady dat dvou výše zmíněných senzorů a porovnat přesnost pixelové a objektově orientované klasifikace pro multitemporální kompozit, případně pro snímek z období, kdy jsou od sebe jednotlivé plodiny dobře rozlišitelné. Pro pixelovou klasifikaci jsou využity metody maximum likelihood a SVM. Využita jsou multispektrální data Sentinel 2-A a 2-B s prostorovým rozlišením 10 m a také data z družice PlanetScope s velikostí pixelu 3,125 m. Dílčím cílem práce je také porovnat přesnost klasifikace při použití dvou typů dat s rozdílným prostorovým

a spektrálním rozlišením.

Práce vychází z předpokladu, že využití multitemporálního datasetu z jedné zemědělské sezóny, během které dochází ke změnám odrážející se ve spektrálním projevu vegetace, by mohlo vést ke zvýšení přesnosti klasifikace vybraných tříd.

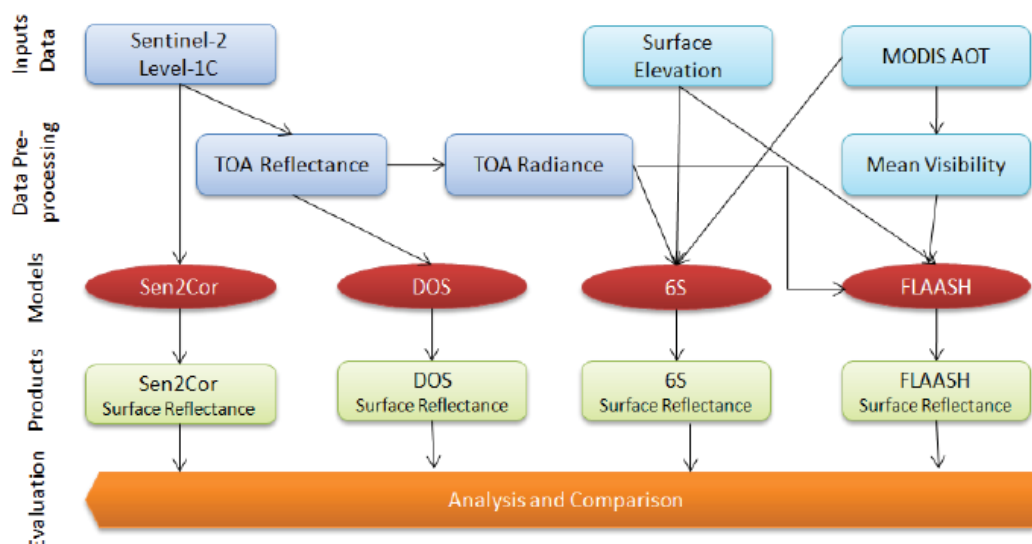
2. Rešerše a úvod do problematiky

Dálkový průzkum Země (DPZ) je jedna z moderních geoinformačních technologií. Výčet oblastí, ve kterých se dá DPZ uplatnit, je velmi rozsáhlý. Identifikace a mapování jednotlivých zemědělských plodin je významnou oblastí v oboru DPZ. Používá se pro stanovení produkce plodin, mapování úrodnosti, nebo i rozpoznávání hlavních zemědělských plodin jako jsou např. ječmen, pšenice, kukuřice atd. Metodika tohoto mapování nejčastěji vychází z multispektrálních a multitemporálních družicových dat vysokého rozlišení. DPZ poskytuje možnost časově efektivního mapování jednotlivých plodin a také zjištění relativně přesných spektrálních či prostorových příznaků těchto plodin (Steven, Clark, 1990). Analýza optických družicových dat zahrnuje několik kroků, mezi něž patří zejména předzpracování dat – korekce a zvýraznění, dále klasifikace a vyhodnocení přesnosti klasifikace.

2.1. Korekce dat

Korekce družicových dat patří mezi první kroky v rámci úpravy a předzpracování dat. Data jsou ovlivněna geometrickým zkreslením, atmosférickými vlivy nebo jsou znehodnocena při vlastním procesu pořizování. Cílem předzpracování obrazu je jeho úprava ve smyslu geometrických a radiometrických vlastností. Geometrické korekce transformují soustavu obrazového záznamu nebo velikost obrazového prvku (pixelu). Radiometrické korekce upravují DN hodnoty jednotlivých pixelů. Součástí radiometrických korekcí jsou i korekce atmosférické, jejichž cílem je minimalizace vlivů (poloha slunce, intenzita slunečního záření, ...) atmosféry při měření odrazových či zářivých vlastností objektů (Dobrovolný, 1998). Každý senzor družice má specifické stupně i způsoby předzpracování dat.

Pro předzpracování obrazových dat Sentinel-2 je možné vycházet z několika možností korekcí dat. Lantzanakis, Mitraka, Chrsoulakis (2016) porovnávají čtyři typy atmosférických korekcí (viz Obr. 1) v rámci různých povrchů zemského pokryvu pro data Sentinel-2. Patří sem korekce 6S (pokročilý algoritmus připravený v NASA pro širokou škálu spektrálních, atmosférických a geometrických podmínek), FLAASH (modul atmosférických korekcí v softwaru ENVI, který koriguje vlnové délky ve viditelných a infračervených oblastech spektra), Sen2cor (modul vyvinutý společností ESA pro atmosférické korekce určené přímo pro data Sentinel-2, díky kterým získáme odrazivost na dolní hranici atmosféry – BOA. Modul navíc provádí automatickou klasifikaci typů zemského povrch, mraků a jejich stínů) a DOS (jednoduchá empirická metoda atmosférických korekcí pro satelitní snímky v modulu ENVI).



Obr. 1: Schéma metod používaných k atmosférické korekci
Zdroj: Lantzanakis, Mitraka, Chrszoulakis, 2016)

Pomocí těchto metod byly porovnány DN hodnoty snímku Sentinel-2 v oblasti Heraklionu v Řecku na těchto typech povrchu: budovy, silnice, industriální prostory, parky, letiště, zemědělské a lesnické oblasti. Pro pixely obsahující stromy a holou půdu vykazovaly všechny modely podobné hodnoty odrazivosti. Pro pixely vody a trávy byly hodnoty z korekcí 6S – Second Simulation of Satellite Signal in the Solar Spectrum FLAASH – Fast Line-of-sight Atmospheric Analysis of Hypercubes a DOS (Dark Object Subtraction) velmi podobné ve srovnání s hodnotami ze Sen2Cor, které byly kompletně rozdílné. Pro urbánní pixely vykazovaly modely též podobnou odrazivost.

V jiné publikaci od Sola et al. (2018) jsou porovnávány metody 6S, MAJA – MACCS ATCOR Joint Algorithm, iCOR – Atmospheric Image Correction for Land and Water a Sen2Cor aplikované na základní typy zemského povrchu (asfalt, holá půda, trávy, pastviny, keře). Na základě koeficientu determinace R^2 se jako nejlepší atmosférická korekce pro travnaté povrchy se zemědělským charakterem jeví Sen2Cor.

2.2. PCA

PCA neboli analýza hlavních komponent je metoda předzpracování či zvýrazňování multispektrálního obrazu. Kromě využití pro vizuální interpretaci se především používá před automatickou klasifikací obrazu. Cílem metody je redukce a transformace vstupních pásem na výstupní pásma nesoucí co nejvíce informací. K přednostem PCA patří, že většina informací z multispektrálního obrazu může být reprezentována několika (zpravidla třemi) prvními komponentami. Výsledkem je redukce rozměrnosti obrazu a také redukce typicky vysoké korelace mezi původními pásmy, která je zároveň efektivní i pro výpočetní a kapacitní účely


(Dobrovolný, 1998).

2.3. Vegetační index NDVI

Normalizovaný rozdílový vegetační index (NDVI) je asi nejznámější a nejvíce používaný vegetační index v DPZ. Jedná se o podíl rozdílu a součtu blízkého infračerveného a červeného pásma. Hodnota NDVI v rozsahu od -1 do 1 popisuje množství zelené vegetace obsažené v pixelu. Čím je hodnota vyšší, tím je také obsah vegetace větší. Negativní hodnoty vykazují obvykle výskyt vody, hodnoty okolo 0 signalizují skály, oblačnost, led nebo sníh. Hodnoty v rozsahu od 0,1 do 0,4 jsou většinou reprezentovány nízkou a až středně hustou vegetací a velmi vysoké hodnoty nad 0,5 indikují velmi hustou vegetaci s vysokým obsahem chlorofylu (Dobrovolný, 1998). NDVI pro určité povrchy vykazují také typické změny v průběhu roku, což bylo využito v celé řadě zemědělských a lesnických aplikací. NDVI je často využíván k tvorbě zdravotních map vegetace a také je využíván ke klasifikaci vegetace a plodin.

2.4. Klasifikace

Klasifikace je metoda zpracování obrazových dat, při které dochází k přiřazení jednotlivých částí obrazu, v tomto případě pixelů, do konkrétních předem definovaných tříd. V průběhu klasifikace jsou původně naměřené radiometrické hodnoty, vyjadřující spektrální vlastnosti pixelů, nahrazeny hodnotami informačních tříd (Dobrovolný, 1998). Základem klasifikace je využití rozhodovacích pravidel neboli klasifikátorů, podle kterých je možné rozřadit pixely do stanovených tříd. Jevy v obraze lze klasifikovat na základě spektrálních, prostorových či časových příznaků, které tvoří příznakový prostor. Rozměrnost tohoto prostoru se odvíjí od počtu spektrálních pásem obrazu. Nejčastěji čtyřrozměrný prostor tvořený pásmy RGB a NIR. Schowengerdt (2007) říká, že předpokladem pro dobře vytvořenou klasifikaci je dostatečná separabilita (oddělitelnost) jednotlivých tříd. Pokud jsou jednotlivé trénovací třídy od sebe dostatečně oddělitelné v příznakovém prostoru (viz Obr. 2), tak mezi sebou vytvoří



dostatečné hranice, které separují výsledné třídy, a klasifikace bude úspěšná. V opačném případě se hranice tříd budou překrývat, pixely se budou „přelévat“ z jedné třídy do druhé a dojde k výrazným klasifikačním chybám, které se projeví ve výsledném obraze.


Existuje mnoho druhů klasifikačních metod, avšak nejčastěji se klasifikace dělí na řízené a neřízené. Klasifikace lze také dělit na pixelovou a objektově orientovanou klasifikaci. V této práci je využita řízená pixelová a řízená objektově orientovaná klasifikace.

2.4.1. Pixelová klasifikace

Při pixelové klasifikaci je využíváno rozdílných vlastností pixelů, přičemž pixely s podobnými vlastnostmi jsou přiřazeny do jedné třídy v příznakovém prostoru na základě klasifikačního pravidla (Halounová, Pavelka, 2005). Řízená pixelová klasifikace vychází z trénovacích ploch, kde jeden typ trénovací množiny představuje třídu jednu definovanou pro klasifikaci (Dobrovolný, 1998). Přesnost a důležitost výběru těchto množin je zásadním faktorem pro výsledek klasifikace. Tento typ klasifikace je výpočtově i kapacitně náročnější, ale přináší přesnější výsledky. Mezi nejznámější klasifikátory spadající pod tuto skupinu patří klasifikátor minimální vzdálenosti, klasifikátor pravoúhelníků nebo klasifikátor maximální pravděpodobnosti.

2.4.1.1. Klasifikátor maximální pravděpodobnosti

Tento klasifikátor předpokládá, že množiny trénovacích pixelů mají normální rozdělení. Využívá rozptyl, korelace, variance a kovariance každé třídy obsahující určité pixely. Také se dokáže vypořádat s překryvy, na rozdíl od jiných metod. Klasifikovaný pixel se řadí do třídy, do které s největší pravděpodobností spadá. Hodnoty stejných pravděpodobností tvoří v n-rozměrném příznakovém prostoru tzv. izoliny, které mají tvar elipsy (viz Obr. 3), a pomocí ní tvoří shluky pixelů. Lze také nastavit prahovou hodnotu pravděpodobnosti, a pokud je tato hodnota pro daný pixel nižší než prahová hodnota, tak pixel nebude klasifikován (Dobrovolný, 1998).




Obr. 3: Schéma přiřazování pixelů dle klasifikátorů
 Zprava: klasifikátor maximální pravděpodobnosti, klasifikátor pravoúhelníků, klasifikátor minimální vzdálenosti
 Zdroj: Dobrovolný, 1998

Klasifikátor maximální pravděpodobnosti je velmi citlivý na případné nedostatky v rozložení trénovacích dat, nicméně pokud jsou trénovací data kvalitní, dává skvělé výsledky.

2.4.1.2. Support vector machines classifier (SVM)

Klasifikace pomocí metody SVM, tedy podpůrných vektorů, patří mezi moderní metody klasifikace obrazových záznamů. Tato metoda využívá efektivní algoritmy, pomocí kterých hledá optimální nadrovinu oddělující data trénovacích množin. Optimální nadrovina je taková, od níž mají datové body jednotlivých tříd největší vzdálenost. V případě lineárně neoddělitelných tříd (viz Obr. 4) provádí transformaci do prostoru s vyšší dimenzí pomocí jádrových funkcí (*kernel function*), kde je možné lineární separability dosáhnout (IS MUNI, 2006). Jádrové funkce mohou být založeny na lineární, polynomické, Gaussovské nebo *sigmoid* separabilitě (Smola, Schölkopf, 2004).



Obr. 4: Princip možnosti lineárního oddělení dvou tříd s nelineárními hranicemi pomocí přidané dimenze
Zdroj: IS MUNI, 2006

SVM byl původně vytvořen pouze jako binární klasifikátor, nicméně byl také rozšířen a aplikován pro klasifikaci více tříd. Vapník (1995) navrhl porovnání jedné třídy s ostatními dohromady (*one against the rest*). Tento postup je založený na principu, že existuje jeden binární SVM pro každou třídu, který se snaží separovat pixely dané třídy od pixelů tříd ostatních. Druhý přístup je založen na principu porovnání dvou tříd proti ostatním (*one against one*). Vždy existuje jeden binární SVM pro každou dvojici tříd, který se snaží oddělit pixely jedné z tříd od ostatních tříd s příslušnými pixely. V publikaci od Pal, Mather (2005) jsou

porovnány tyto dvě metody SVM, které byly využity ke klasifikaci dat Landsat ETM+ k rozlišení sedmi typů krajinného povrchu. Z výsledků vyplývá, že větší přesnosti bylo dosaženo metodou *one against one*. V rámci této publikace byly porovnány i metody klasifikace maximální věrohodnosti a neuronových sítí, ale klasifikátor SVM dosáhl největší přesnosti (Huang, Davis, Townshend, 2002).


2.4.2. Objektová klasifikace

Základním principem objektově orientované klasifikace (OBIA) je, že informace získané z obrazu při klasifikaci nejsou reprezentovány jednotlivými pixely, nýbrž objekty a jejich vzájemnými vztahy (Baatz, Schäpe, 2000). Objektová klasifikace začíná vždy tzv. segmentací obrazu, kde pomocí předem definovaných parametrů jsou obrazová data rozdělena do určitých segmentů (objektů). Následně jsou nastavena klasifikační pravidla. Oproti pixelové klasifikaci zde hrají roli i tvarová, texturní a velikostní kritéria objektů. Samotná klasifikace pracuje na stejném principu jako pixelová, pouze jsou porovnávány a do předem definovaných tříd přiřazovány samotné objekty a nikoli jednotlivé pixely.

2.4.2.1. Segmentace obrazu a její metody


Obrazová segmentace je dělení obrazových dat v geografickém a příznakovém prostoru do oddělených objektů, regionů, shluků s jasně definovanou mírou heterogenity / homogenity. Segmentace vychází ze dvou základních přístupů. Prvním je tzv. strategie *top-down*, při které se obraz regionalizuje z větších částí na menší. Druhou možností je strategie *bottom-up*, v průběhu které jsou spojovány menší objekty do větších.

Mezi základní metody segmentace patří tzv. *chessboard segmentation*. Je to segmentace *top-down*, neboť rozděluje obraz do stejných čtverců určité velikosti (viz Obr. 5). Tato metoda je vhodná spíše pro statistické výpočty, kdy např. chceme extrahovat hodnoty obrazu do stejných oblastí.



Obr. 5: Chessboard segmentation
Zdroj: vlastní, 2018

Další metodou je segmentace *quad tree segmentation*. Postupně dochází k dělení obrazu do čtverců různých velikostí (strategie *top-down*). Nejprve se vytvoří výchozí počáteční síť a poté je každý čtverec dělen do čtyřúhelníků (viz Obr. 6), dokud se nedosáhne požadovaného stupně homogenity v čtyřúhelnících.



Obr. 6: Princip segmentace pomocí metody *quad tree segmentation*
Zdroj: vlastní, 2018

Nejúčinnější metodou pro klasifikaci obrazu na výrazně heterogenní objekty je *multiresolution segmentation*. Patří do skupiny *bottom-up*, neboť propojuje pixely nebo menší objekty do větších celků (viz Obr. 7). Samotná segmentace začíná na úrovni jednoho pixelu a



Obr. 7: Rozdělení obrazu pomocí metody *multiresolution segmentation*
Zdroj: (Batz, Schäpe, 2000)

postupně spojuje jednotlivé pixely do větší segmentů tak dlouho, dokud není dosaženo homogenity jednotlivých prvků. Celková homogenita je definována kombinací spektrální a tvarové homogenity (kompaktnost, velikost, textura). Regionalizace objektů se dá ovlivnit i měřítkovým parametrem – *scale parameter*. Při zadání vyšší hodnoty se tvoří větší objekty, a naopak při nízké hodnotě jsou objekty malé (Batz, Schäpe, 2000).

2.4.3. Multitemporální přístup ke klasifikaci plodin

Objekty či jevy v obraze lze klasifikovat i na základě jejich časových příznaků. Buď můžeme klasifikovat několik jevů na základě jednoho časového okamžiku (monotemporální přístup), nebo využijeme klasifikaci vycházející z více časových okamžiků (multitemporální

přístup). Data z různých časových období jsou spojena do jednoho multitemporálního datasetu, který obsahuje několik kombinací stejných pásem na základě zdroje dat. Dobrovolný (1998) uvádí, že při identifikaci zemědělských plodin se s časem mění spektrální a prostorové příznaky v průběhu vegetačního cyklu. Více obrazových dat z různých časových intervalů umožňuje lepší identifikaci druhů plodin. Dle Lu et al. (2004) lze tedy říci, že multitemporální přístup zkoumá změnu spektrálních charakteristik objektů za účelem lepšího odlišení vybraných prvků, čehož následně využívá při zlepšování přesnosti klasifikace.

V případě snímání povrchu družicí Sentinel-2 je možné mít každých pět dnů data ze stejného území. Senzorové a orbitální charakteristiky umožňují uživatelům bezprecedentní časové a spektrální informace při vysokém rozlišení dat a zároveň jsou data vhodná pro studium vegetační fenologie. Detailní spektrální charakteristiky obrazu obsažené v desetipásmových snímcích poskytují možnosti pro zlepšení přesnosti klasifikace zemědělských plodin (Vuolo et al., 2018).

Při tvorbě multitemporálního datasetu je potřeba zmínit i otázku atmosférických korekcí, neboť ne v každém časovém okamžiku při snímání povrchu se atmosféra chová stejně. Song et al. (2004) popisuje, že pokud jsou multitemporální data v jednom datasetu a trénovací plochy jsou vybírány nad všemi pásmy, tak není potřeba provádět atmosférické korekce.

Jeden z prvních pokusů klasifikace zemědělských plodin z dat Sentinel-2 byl prezentován v článku od Immitzer et al. (2016), kde se autoři zaměřili na klasifikaci šesti zemědělských plodin – jařin (mrkev, kukuřice, cibule, sója, cukrovka a slunečnice) a skupinu ozimů, které tvořily jednu třídu. Jako modelové území byla zvolena oblast Marchfield o přibližné rozloze 1000 km² v Dolním Rakousku. Byl využit monotemporální přístup a klasifikace proběhla na základě snímku ze srpna 2015 – tedy konce zemědělské sezóny. Využito bylo všech deset pásem, kde pásma s velikostí 20 m byla převzorkována na velikost 10 m, aby mohl vzniknout společný dataset o velikosti pixelu 10 m. Na data byly aplikovány jak pixelová, tak objektově-orientovaná klasifikace na základě metody RF (*Random Forest*). Studie také popisuje vysoký vliv pásem v oblastech spektra RED EDGE a SWIR pro mapování plodin. Také pásmo BLUE mělo vysoký vliv na klasifikaci. Naopak oblast NIR měla vliv podstatně menší.

Na předchozí článek navazují se svou studií Vuolo et al. (2018), kteří se snaží demonstrovat výhodu multitemporálního datasetu oproti monotemporálnímu ve prospěch zvýšení přesnosti klasifikace plodin. Autoři zde vychází z podobného modelového území v Dolním Rakousku a

jako své klasifikační třídy zvolili devět plodin: mrkev, kukuřice, cibule, brambory, dýně, sójové fazole, cukrovka, slunečnice a společnou skupinu ozim. Využito bylo opět deset pásem z každého datasetu Sentinel-2. Byly vytvořeny dva multitemporální datasety z období března až října. Dataset z roku 2016 byl složen z osmi snímků a dataset z roku 2017 deseti snímků. Na obou byla provedena pouze pixelová klasifikace pomocí metody RF. Zároveň byly klasifikovány veškeré snímky zvlášť, aby se zjistilo, v kterých obdobích dosahuje klasifikace největší přesnosti. Ze studie vyplývá, že období z jara (březen až duben) není vhodné pro rozeznání plodin, jelikož vegetace teprve začíná růst. Klasifikace v tomto období měla velmi malou celkovou přesnost. Naopak v průběhu vrcholu vegetační sezóny (červen) bylo dosaženo nejlepších výsledků.

2.4.4. Hodnocení přesnosti klasifikace

Úspěšnost každé klasifikace je zpravidla posuzována na základě její přesnosti. Za chybu v klasifikaci je považován případ, kdy danému pixelu je přiřazen význam jiné třídy. Jedním z přístupů hodnocení přesnosti je výpočet pomocí chybové matice (viz Obr. 8). Chybová matice porovnává u všech kategorií vztah mezi referenčními daty a výsledky klasifikace. Hodnocena je jednak celková přesnost (počet všech pixelů tříd, které byly zařazeny správně, vzhledem k celkovému počtu kontrolních dat), uživatelská přesnost (počet správně klasifikovaných pixelů vůči celkovému počtu pixelů zařazených do třídy) a zpracovatelská přesnost, kterou definuje počet správně klasifikovaných pixelů vůči počtu pixelů použitých pro testování dané třídy (Dobrovolný, 1998). Dále jsou hodnoceny chyby z opomenutí (součet pixelů ve sloupci mimo hlavní diagonálu vůči počtu pixelů referenčních dat) a chyby z nesprávného zařazení (součet pixelů v řádku mimo diagonálu vůči počtu pixelů referenčních dat).

	třída	Referenční data					SUMA	PU [%]
		Voda	Les	Pole	TTP	Půda		
klasifikovaná data	Voda	480	0	5	0	0	485	99
	Les	0	52	0	20	0	72	72
	Pole	0	0	313	40	0	353	89
	TTP	0	16	0	126	0	142	89
	Půda	0	0	0	38	342	380	90
	SUMA	480	68	318	224	342	1432	
	CHO [%]	0	23	1	44	0		
	CHZ [%]	1	29	13	7	11		
	PZ [%]	100	76	98	56	100		

Průměrná přesnost: $(480 + 52 + 313 + 126 + 342) / 1432 = 92 \%$

CHU - chyba z opomenutí

CHZ - chyba z nesprávného zařazení

PU - přesnost z hlediska uživatele

PZ - přesnost z hlediska zpracovatele

Obr. 8: Hodnocení klasifikace pomocí chybové matice

Zdroj: Dobrovolný, 1998

2.5. Fenologie plodin

Fenologie je vědní disciplína, která se zabývá studiem časového průběhu periodicky se opakujících životních projevů rostlin (v případě zemědělských plodin) a živočichů v závislosti na podmínkách vnějšího prostředí. Základem fenologie jednotlivých plodin jsou tzv. fenologické fáze, které jsou popsány jako každoročně se opakující projevy vývinu plodin. Jednotlivé fenofáze (např. setí, rašení, klíčení, hlavní vegetační fáze, sklizeň, ...) jsou pak popsány výčtem znaků, jejichž současný výskyt charakterizuje fenofázi a umožňuje ji rozpoznat jako určitý moment nebo úsek v procesu vývinu rostliny (Sera, Hájková, 2014). Právě časové rozmezí fází v průběhu roku je klíčem ke zjištění příznaků pro jednotlivou plodinu, aneb ve které fázi jsou plodiny od sebe navzájem nejlépe odlišitelné a naopak. Velkou roli pro jednotlivé fenofáze hraje především typ plodiny (ozim nebo jařina) zeměpisná šířka a celkově i klima.

2.5.1. Ozim


Ozim je označení pro plodinu, která se vysévá na podzim a sklízí v létě následujícího roku. Patří do kategorie dvouletých rostlin, neboť zpravidla na podzim vyklíčí, poté přezimuje ve vegetativním stavu a na jaře pokračuje v růstu, vykvete a poté je sklizena. Patří sem např. ječmen ozimý, pšenice ozimá a řepka ozimá.

2.5.2. Jařina

Opakem ozimých plodin jsou tzv. jařiny. Jsou to plodiny, které se vysévá na jaře a sklízí v letních měsících téhož roku. Zpravidla se jedná o speciální odrůdy, které jsou k tomu uzpůsobené a tyto odrůdy mají kratší vegetační období. Patří sem např. ječmen jarní, pšenice jarní a kukuřice.

2.5.3. Vegetační fáze plodin


Bargiel (2017) ve svém výzkumu (klasifikace plodin v oblasti kolem Hannoveru v Německu – tedy stejná zeměpisná šířka jako ČR) názorně ukazuje životní cyklus pšenice ozimé, kukuřice a cukrovky (viz Obr. 9). Jednotlivé fenofáze rozdělil na *preparation* – preparace půdy, *crop seed* – setí plodiny, *life cycle* – životní cyklus rostliny končící hlavní vegetační fází, *harvest stage* – období sklizně a *post harvest* – období po sklizni. Z obrázku vyplývá, že je zde jasný rozdíl mezi ozimou plodinou (*winter wheat* – pšenice ozimá)



Obr. 9: Životní cyklus pšenice ozimé, kukuřice a cukrovky
Zdroj: Bargiel, 2017


a jařinami (*maize* – kukuřice a *sugar beet* – cukrovka). Cukrovka a kukuřice mají velmi podobné fenofáze na rozdíl od pšenice. Pšenice zase dříve vyklíčí a také je dříve sklizena. Z obrázku vyplývá, že nejlepší období pro zjištění spektrálních příznaků pšenice ozimé je rozmezí června až července, pro kukuřici cca v srpnu a pro cukrovku červen až září.

Nejobtížněji od sebe separovatelné z plodin studovaných v článku Zheng et al. (2015) jsou pšenice ozimá a ječmen ozimý. Na základě spektrálních grafů (viz Obr. 10) indexu NDVI autoři




Obr. 10: Spektrální projevy NDVI pšenice ozimé, ječmene ozimy a kukuřice
Zdroj: Zheng et al., 2015

sledují průběh NDVI a určují dobu, kdy dosáhne maxima, což je v DPZ jeden z častých a vhodných způsobů sledování fenologie. Z grafů je patrné, že křivky pro pšenice ozimou a ječmen ozimý vysoce korelují. To samé se dá říct i o jejich vegetačních fázích, kdy výsev (*planting*) probíhá v období podzim až zima a sklizeň (*harvest*) je provedena v měsících květen a červen (viz Obr. 11). Naopak kukuřice (jařina) dosahuje nejvyšších NDVI hodnot v červnu, oproti předchozím dvěma plodinám, které mají maximum v dubnu. Studie nicméně proběhla v semiaridní oblasti Phoenixu v USA a vegetační fenofáze se vzhledem k rozdílnému klimatu mírně liší ve smyslu, že sklizeň je posunuta o cca jeden měsíc dříve oproti ČR.



Obr. 11: Porovnání fenofází jednotlivých plodin
Zdroj: Zheng et al., 2015


Pan et al. (2015) využili pro zjištění fenologických parametrů časovou řadu NDVI z dat družice HJ-1 A/B (čtyři spektrální pásma RGB a NIR, prostorové rozlišení 30 m). Studie proběhla v čínské provincii Shaanxi v letech 2011 a 2012. Pro extrakci jednotlivých fenologických fází využili software TIMESAT, který identifikuje jen ty pixely, které mají charakteristiku vegetace. Tyto pixely byly automaticky vyčleněny a pro ně byly zjišťovány fenologické parametry (start a konec sezóny, střed sezóny, délku sezóny a maximální hodnotu NDVI) pro kukuřici a pšenici ozimou. Z obrázku (viz Obr. 12) vidíme opět dobrou odlišitelnost pšenice ozimé od kukuřice s tím, že nejvhodnější období pro klasifikaci pšenice ozimé je duben – květen a pro kukuřici přibližně srpen. Obě plodiny dosahují v těchto obdobích vegetačního vrcholu.



Obr. 12: Fenologické fáze pšenice ozimé a kukuřice
a) začátek klíčení pro pšenici; b) maximální hodnota NDVI, vrchol vegetační sezóny pro pšenici; c) sklizeň pro pšenici a začátek klíčení pro kukuřici; d) délka vegetační sezóny pšenice; e) maximální hodnota NDVI, vrchol vegetační sezóny pro kukuřici; f) sklizeň pro kukuřici a výsadba pro pšenici; g) délka vegetační sezóny kukuřice; h) začátek období přezimování pro pšenici
Zdroj: Pan et al., 2015

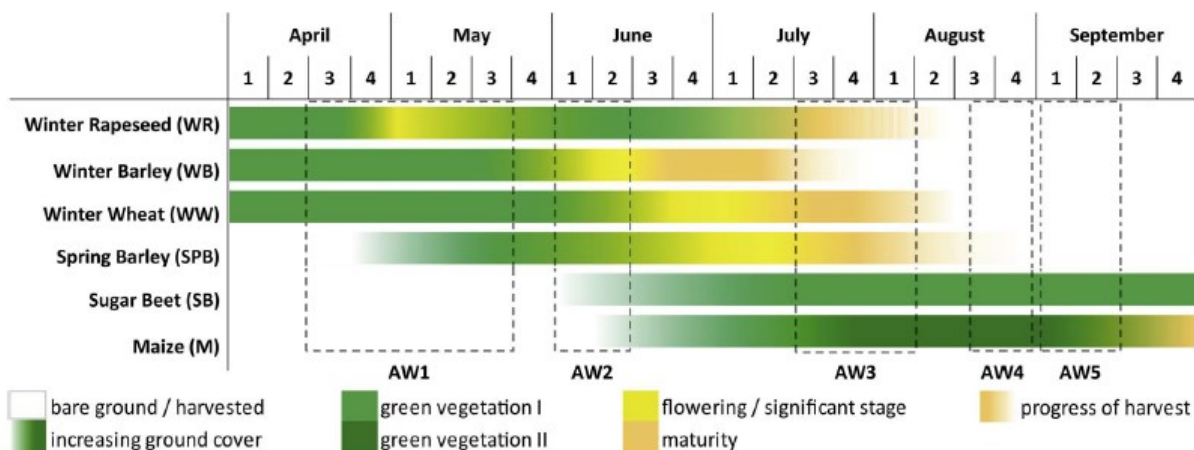
Podobný princip ke zjištění klasifikačních příznaků pro vybrané plodiny využívají Belgiu, Csillik (2018), kteří k určení temporálních fenologických příznaků využívají časovou řadu S-2 vytvořenou z indexu NDVI. Studie proběhla na třech testovacích územích (region Bräila v Rumunsku, jižní Lombardie v Itálii a region Imperial v jižní Kalifornii). Pro účely této práce

byla vybrána pouze první dvě území, jelikož se nacházejí v podobných zeměpisných šířkách jako ČR. Z grafů (viz Obr. 13), ve kterých se zaměřím pouze na plodiny kukuřice (*maize*) a pšenice (*wheat*) v *Test area 1* (TA1) a kukuřice a ozimé plodiny tvořené z pšenice ozimé a ječmene ozimého (*winter cereals*) v *Test area 2* (TA2) vyplývá, že pšenice ozimá v TA1 má periodu maximálního růstu v květnu a sklizeň na konci června. Kukuřice vykvétá později a maximální hodnoty NDVI dosahuje od července do srpna a v září následuje sklizeň. V TA2 dosahují ozimé plodiny vrcholu své vegetační fáze na přelomu dubna a května a sklizeň probíhá v červnu. Kukuřice dosahuje vrcholu vegetační fáze v červenci a sklizeň probíhá v září. Křivky pro pšenici ozimou a ozimé plodiny jsou téměř totožné, pro kukuřici se mírně liší, a to především v období těsně po vrcholu hlavní vegetační fáze. V zásadě jsou ale příznaky těchto plodin (pšenice ozimá, ječmen ozimý, kukuřice) poměrně stabilní, a to i přesto, že se jedná o odlišná území.



Obr. 13: Temporální příznaky plodin pomocí indexu NDVI ve dvou testovacích územích
Zdroj: Belgiu, Csillik, 2018

Waldhoff, Lussem, Bareth (2017) tvrdí, že pro diferenciaci typů plodin z optických dat je fenologie plodiny klíčovým faktorem. Na Obr. 14 vidíme sedm fenofází jednotlivých plodin: WR – řepka ozimá, WB – ječmen ozimý, WW – pšenice ozimá, SPB – ječmen jarní, SB – řepka jarní, M – kukuřice.



Obr. 14: Fenofáze jednotlivých plodin v průběhu roku
Zdroj: Waldhoff, Lussem, Bareth, 2017

SB – cukrovka, M – kukuřice. Přerušované polygony reprezentují časové úseky, v kterých proběhlo mapování. Jednotlivé barvy indikují průměrný výskyt významných fází vývoje druhů plodin ve spojení s jejich typickým projevem v DPZ. Bílá barva značí období výskytu holé půdy nebo nepatrné přízemní vegetace. Odstíny zelené barvy značí přítomnost různých stupňů vegetace. U obilovin (ječmen, pšenice) a částečně i řepky se zelená barva mění na žlutou, a právě tento časový úsek je signifikantní pro diferenciaci druhů plodin. Např. kvůli poměrně brzkému kvetení je řepka nejlépe identifikována od druhé poloviny dubna až do poloviny května. U dalších plodin (pšenice a oba ječmeny) je spektrální průběh velmi podobný. Nicméně spektrální projev ječmene ozimy od pšenice ozimé se většinou liší v první polovině června. Je to způsobeno skutečností, že ječmen ozimý v tomto období už kvete, ale pšenice je teprve ve fázi klíčení. Naproti tomu cukrovka a kukuřice jsou v tomto období teprve vysévány a jejich spektrální odlišitelnost se projeví nejvíce koncem července či srpna. Na základě konceptu fenofází byly vytvořeny časové třídy (viz Obr. 15), ve kterých lze nejlépe klasifikovat

acquisition period	April/May (time step 1)		June	July	August	September	final crop class
crop type	Winter Rapeseed		Winter Rapeseed	Bare Ground*	Bare Ground*	Bare Ground*	Winter Rapeseed
	Winter Cereal	Winter Wheat	Winter Wheat	Winter Wheat	Bare Ground*	Bare Ground*	Winter Wheat
		Winter Barley	Winter Barley	Bare Ground *	Bare Ground*	Bare Ground*	Winter Barley
	Bare Ground		Bare Ground	Bare Ground/ Maize	Maize	Maize	Maize
			Bare Ground	Bare Ground/ Sugar Beet	Sugar Beet	Sugar Beet	Sugar Beet
	Bare Ground/ Potato		Bare Ground/ Potato	Potato/ Bare Ground *	Potato/ Bare Ground *	Potato/ Bare Ground*	Potato
	Bare Ground/ Spring Barley		Spring Barley	Spring Barley	Spring Barley/ Bare Ground*	Spring Barley/ Bare Ground*	Spring Barley

Crop Type Derivation Workflow

Obr. 15: Diagram plodin ke klasifikaci

*šedě vyznačené čtverce s plodinami indikují nejvhodnější období pro jejich rozeznání

Zdroj: Waldhoff, Lussem, Bareth 2017

jednotlivé plodiny. Mapování proběhlo v západním Německu v regionu North Rhine-Westphalia v roce 2015 v časových obdobích 15. a 23. dubna, 4. června, 1. a 30. srpna, 29. září a 1. listopadu. Multispektrální snímky z družice RapidEye a Landsat 8 byly využity jako zdrojová data. Ke klasifikaci byly využity metody ML a SVM s kernelovskou funkcí RBF, která je dle autorů nejvhodnější pro tyto účely. Nicméně nepatrně lepší výsledky přinesla klasifikace metodou ML.

2.6. Metody klasifikace pro mapování zemědělských plodin

V současné době existuje nespočet zdrojů, studií či metod zaměřených na identifikaci zemědělských plodin. Nicméně žádná z nich nedosahuje přesných a jednoznačných výsledků. Hlavním problémem je poměrně nízká heterogenita plodin v průběhu roku, a právě proto je obtížné od sebe plodiny odlišit.

Většina technik vyvinutých pro klasifikaci povrchu je založena na rozdílech v radiometrických vlastnostech zemského povrchu, a proto bylo dříve možné klasifikovat jen základní typy povrchu. Dříve byly dostupné pouze vlnové délky soustředící se na několik klíčových viditelných nebo blízkých infračervených pásem. Dnes se již používají vlnové délky od ultrafialové až po mikrovlnné elektromagnetické spektrum, umožňující detailní mapování a to i díky zlepšení prostorového rozlišení až na centimetry. Během posledních dvaceti let se techniky snímání výrazně zlepšily a postupně se objevují nové metody či klasifikační techniky k detailnímu rozpoznání vegetačních plodin (Mulla, 2013).

Publikace od Moran, Inoue, Barnes (1997) popisuje, že současné senzory satelitních družic poskytují kvalitní časové a prostorové rozlišení a celkově vysokou kvalitu očekávanou k identifikaci zemědělských plodin. Hlavním limitem k rozpoznání plodin jsou vlastnosti senzoru jako jeho omezený spektrální rozsah, hrubé prostorové rozlišení, časové rozlišení a nedostatečné pokrytí opakovaným snímáním. Dle názorů expertů z té doby by se měly budoucí práce soustředit na sjednocení informací z různých systémů DPZ podporující dlouhodobé projekty s cílem získat přesnější informace o zemědělských plodinách. Nicméně trend je jiný a ani po dvaceti letech se nedaří získávat požadované informace. Na druhou stranu dochází k postupnému zlepšení. Dle autorů publikace jsou k identifikaci plodin potřeba tři základní typy informací: informace o stabilních sezónních podmínkách, informace o proměnlivých sezónních podmínkách (vlhkost půdy, klima, napadení hmyzem, ...) a informace vedoucí k diagnostice variability a růstu plodin ovlivněných prvními dvěma kategoriemi.

Jeden z nových postupů je demonstrován v článku Mangiarotti et al. (2017) a je to metoda globálního modelování (*Model-based classification*). Je to klasifikace založená na přístupu, který zohledňuje dynamické chování v procesu detekce plodin. Navzdory tomu, přístupy založené na tomto modelu jsou příliš náročné a nákladné na časové zpracování. Studie založená na tomto modelu klasifikace byla provedena v Indii v oblasti povodí Berambami na multitemporálním datasetu o sedmnácti snímcích z dat Landsat 8 od 11. února 2014 do

6. června 2016. Klasifikovány byly tyto plodiny: slunečnice, cirok, měsíček, kukuřice, kurkuma, červená řepa, cibule, fazole a chilli. Přesnost klasifikace byla spočítána pomocí chybové matice, avšak s velmi rozdílnými hodnotami přesnosti pro každou plodinu s tím, že nejvyšší přesnosti dosáhla třída kukuřice. Studie také zmiňuje, že využití multitemporálního datasetu je mnohem efektivnější než klasifikace z jednoho časového termínu.

Zajímavé mapování zemědělských plodin provedli Belgiu, Csillik (2018). Studie porovnává přesnost pixelové a objektově-orientované klasifikace vytvořené z dat Sentinel-2. Byla definována tři testovací území: region Brăila v Rumunsku, jižní Lombardie v Itálii a region Imperial v jižní Kalifornii. Pro jednotlivá území byly zvoleny třídy na Obr. 16. Mapování proběhla v období od ledna do prosince 2016. Jako temporálně fenologické parametry pro každou plodinu byly definovány indexy NDVI, které dohromady tvořily multitemporální dataset o třinácti snímcích pro první a druhé území a jednadvaceti snímcích pro území třetí. Na tři datasety byly následně aplikovány pixelové a objektově-orientované klasifikace pomocí metod RF a TWDTW (*Time-weighted Dynamic Time Warping*). Nejprve se vygenerují temporální příznaky vytvořené z NDVI kompozitu, poté se aplikuje TWDTW analýza, a nakonec proběhne klasifikace. Metoda byla upravena tak, aby zohledňovala sezónní průběh jednotlivých plodin. Z výsledků vyplývá, že největší přesnosti bylo dosaženo při klasifikaci pomocí metody TWDTW a při objektově-orientované klasifikaci.

Test area 1			Test area 2			Test area 3		
Class	Train.	Valid.	Class	Train.	Valid.	Class	Train.	Valid.
Wheat	38	89	Double cropping	59	124	Durum wheat	26	60
Maize	32	73	Forage	45	80	Alfalfa	69	160
Rice	24	57	Forest	41	102	Other hay/Non alfalfa	50	116
Sunflower	30	71	Maize	42	147	Sugar beets	38	89
Forest	32	73	Water	33	68	Onions	21	49
Water	25	57	Winter cereals	31	84	Fallow/Idle cropland	33	76
						Lettuce	24	56
Total	181	420	Total	251	605	Total	261	606


Obr. 16: Klasifikační třídy a počet jejich trénovacích a validačních ploch
Zdroj: Belgiu, Csillik, 2018

Jednoduchou klasifikaci čtyř základních zemědělských plodin (rýže, pšenice, ječmen a oves) provedli ve své studii Kondratyev, Fedchenko (1981). Snažili se demonstrovat, které z vlnových délek (440, 550, 600, 650, 840 a 1015 nm) EM spektra jsou nejvhodnější pro klasifikaci zmíněných plodin. Nejprve byly změřeny odrazivosti jednotlivých plodin v terénu

(vícekanálovým fotometrem, pracujícím na principu měření spektrálního jasů) a na základě toho byly vybrány tři nejvhodnější vlnové délky (550, 650 a 840 nm), ze kterých lze nejlépe od sebe odlišit plodiny. Následně byla ke klasifikaci využita metoda *Maximum likelihood* s poměrně příznivými výsledky. Studie je zastaralá, ale z výsledků a měření vyplývá, že nejvhodnější vlnové délky pro mapování čtyř zmíněných plodin (tři z nich jsou zahrnuty v této práci) jsou pásma GREEN – 550 nm, RED – 650 nm a NIR – 840 nm.

Klasifikační metodu SVM využili ve své studii Zheng et al. (2015), kteří se zaměřili na systematické monitorování zemědělských plodin a jejich příznaků v průběhu roku. Studie byla založena na klasifikaci šesti zemědělských plodin (vojtěška, bavlna, kukuřice, ječmen, pšenice, brambory) a tří kombinovaných plodin (ječmen-bavlna, pšenice-cirok a pšenice-bavlna) v oblasti PHX AMA v centrální Arizoně. Z dat Landsat 7 a 5 z období 9. ledna až 11. prosince byl vytvořen multitemporální NDVI dataset o dvaadvaceti vrstvách, na které byl aplikován klasifikátor SVM s funkcí RBF (*Radial Basis Function*). Autoři se snažili porovnat dvě metody výběru trénovacích dat. První metoda byla založená na výběru rovnoměrných trénovacích množin na základě *stratified random approach* (náhodný výběr z vrstvy CDL – *Cropland Data Layer*). Druhý přístup vycházel z tzv. *intelligent sample selection* (inteligentní výběr trénovacích ploch), kde pro jednotlivé plodiny byly vybrány pouze vzory nezbytné pro diferenciaci mezi spektrálně podobnými třídami. Celkově byla dosažena vysoká přesnost klasifikace s nepatrnou větší přesností ve prospěch *intelligent sample selection*.

Zajímavou metodu pro klasifikaci plodin popisuje Bargiel (2017). Studie byla ale založena radarových datech Sentinel-1 a uskutečnila se na území severního Německa na třicetidevíti km² plochy. Pro klasifikaci deseti plodin (travnaté porosty, brambory, kukuřice, řepka jarní, cukrovka, ječmen jarní, ječmen ozimý, žito, oves a pšenice ozimá) využívá charakteristiku PSP



Obr. 17: Ukázka fenologických etap pro plodiny a travnaté porosty
Zdroj: Meier, Bleiholder, 2006

(*Phenological Sequence Patterns*), která je zakomponována do klasifikační metody, a je založená na fenologických etapách plodin v průběhu roku. Fenologická etapa vychází z fenologie plodinu (doba setí, klíčení, sklizně, morfologické a fyziologické vlastnosti) a pro každou plodinu bylo definováno šest etap (viz Obr. 17): zimní etapa bez vyklíčení, prvních osm týdnů sezóny, perioda do sklizně, následujících devět týdnů, následující čtyři týdny a zbytek sezóny. Každá fenologická etapa je popsána jedinečnými vlastnostmi, které ji odlišují od další etapy jednotlivé plodiny. Následně jsou jednotlivým etapám pro každou plodinu přiřazeny relativní hodnoty vycházející ze škálovatelného měřítka *BBCH-scale* (stupnice vývojových a růstových stádií rostlin) od Meier, Bleiholder (2006). Stupnice *BBCH-scale* je systém jednotného kódování fenologicky podobných etap růstu zemědělských plodin. Pro klasifikaci byly vytvořeny dva multitemporální datasety ze sezón 2014/2015 a 2015/2016. Jako klasifikační metody byly použity *Maximum likelihood* a *Random forest* nejprve bez začlenění a poté se začleněním PSP a následně byly výsledky validovány pomocí vzorce vycházejícího z kombinace $F1 = 2 \times \frac{PA \times UA}{PA + UA}$, kde PA je zpracovatelská a UA je uživatelská přesnost.

Sonobe et al. (2018) využívají ke klasifikaci plodin tzv. vegetační indicie. Vegetační indicie (bylo jich využito celkem osmdesátjedna) jsou reprezentovány různými vegetačními indexy přizpůsobenými přímo pro data Sentinel-2. Z vegetačních indicií byl vytvořen multitemporální dataset vytvořený z deseti pásem (RGB, NIR 1, NIR 2, SWIR 1, SWIR 2 a RED EDGE 1 až 3), reprezentující časové období od května do srpna 2016. Plodiny jako fazole, kukuřice, brambory, pšenice, travnaté porosty a červená řepa zastupovaly klasifikační třídy. Klasifikace proběhla na území *Tokachi plain* v japonském Hokkaidu. K pixelové klasifikaci byla využita metoda SL (*Super Learner*), metoda *Random Forest* a metoda SVM s kernelovskou funkcí RBF, která je podle studie nejvhodnější pro klasifikaci plodin. Validace výsledků byla popsána na základě celkové, uživatelské a zpracovatelské přesnosti. Nejlepší celkovou přesnost vykazovala metoda SL. Data z družice Sentinel-2 se senzorem MSI byla velmi užitečná pro klasifikaci plodin pomocí vegetačních indexů.

Podobný princip využívají ke klasifikaci plodin Ustuner et al. (2014), kteří vycházejí z dat vysokého rozlišení RapidEye s velikostí pixelu 5 m. Ke klasifikaci pomocí metody SVM využívají tři vegetační indexy: NDVI, GNDVI a NDRE. Jako modelové území byl zvolen region Aegean v Turecku. Klasifikovány byly tyto plodiny či typy povrchu: *first crop corn* – první kukuřičná plodina, *second crop corn* – druhá kukuřičná plodina, *well developed cotton* – dobře vyvinutá bavlna, *moderate developed cotton* – středně vyvinutá bavlna, *weak developed cotton* – slabě vyvinutá bavlna, *wet soil* – mokrá půda, *moist soil* –

vlhká půda, *dry soil* – suchá půda, *water surface* – vodní plocha. Klasifikace vychází z jednoho časového okamžiku (publikace ale nezmiňuje rok ani přesný datum) a autoři se snaží klasifikovat nejprve každý index zvlášť a poté v rámci různých kombinací a snaží se zjistit, který index, popřípadě kombinace, přináší nejlepší výsledky pro identifikaci plodin. Výsledky ukazují, že kombinace všech tří indexů vykazuje největší celkovou přesnost klasifikace a zároveň index NDRE je oproti zbylým dvou přesnější ke klasifikaci vybraných tříd.

Další studií, která využívá vegetační indexy, je publikace Psomiadis et al. (2017). V rámci ní byly vytvořeny dva experimentální přístupy, které porovnávaly dva vegetační indexy a to NDVI a LAI pro bavlnu a pšenici jarní a pšenici ozimou v oblasti Thessaly Plain v Řecku. Jako zdrojová data byly využity snímky z družic Sentinel-2 a WorldView-2 (prostorové rozlišení 2 m). Vegetační indexy byly vytvořeny ze čtyř časových období. Pro pšenici ozimou a bavlnu byly použity snímky z dubna, jak pro S-2, tak pro WV-2 a pro pšenici jarní a bavlnu snímky z června. Indexy byly spočítány, poté statisticky porovnány z důvodu zjištění jejich korelace či závislosti. Do statistik bylo nakonec začleněno dalších 5 vegetačních indexů (RECI, TNDVI, MCARI, RECI, PSSRa) proto, aby byla zjištěna jejich ne/efektivita v rámci detekce problematických oblastí růstu plodin. Z výsledků vyplývá, že statistické křivky vykazují podobně kolísavé hodnoty jak pro obě pšenice, tak pro bavlnu. Statistika založená na NDVI vykazuje lepší podobnost vůči koeficientu determinace R^2 v případě pšenice v dubnu, zatímco statistika z indexu LAI vykazuje lepší podobnost bavlny v červnu vůči koeficientu R^2 . Skutečností je, že v okolí bavlny se vyskytovalo hodně holé půdy, a protože index LAI je založen na indexu SAVI, který je vhodnější pro diferenciaci půdní odrazivosti, tak je zřejmé, že v případě bavlny bylo dosaženo lepších výsledků na základě indexu LAI. Nicméně hodnoty vytvořené na základě obou indexů vykazují vysokou korelaci pšenice a bavlny. Z detailnější analýzy na základě koeficientu determinace R^2 vyplývá, že oba typy dat dávají porovnatelné výsledky navzdory tomu, že S-2 má mnohem menší prostorové rozlišení než WV-2.

Mondal et al. (2014) využívají ke klasifikaci plodin kromě NDVI indexu také vegetační indexy EVI2 a NDSBVI. Cílem této studie je vyvinout poloautomatický postup využívající multispektrální satelit IRS Resourcesat-2 LISS-III (prostorové rozlišení 23,5 m a čtyři spektrální pásma – GREEN, RED, NIR, SWIR) k extrakci ročního výnosu plodin v oblasti Bihar v Indii. V rámci studie byl během roku 2012 proveden terénní průzkum za účelem seznámení se s fenologií jednotlivých plodin v průběhu roku. Jednotlivé indexy byly spočítány a dohromady byly spojeny do jednoho kompozitu. Následně byla provedena extrakce ploch na základě intenzity obrazu a bylo rozlišeno celkem sedm tříd (dvě odrůdy rýže, pšenice, kukuřice,

cukrová třtina, mango a liči) a nakonec byla spočítána statistická regrese, ze které vzešla mapa plodin. Na základě celkové přesnosti vykazoval nejlepší výsledky index NDVI v rámci extrakce plodin. Nicméně uživatelská a zpracovatelská přesnost pro jednotlivé plodiny není zmíněna.

Mapování zemědělských plodin pomocí časové série indexu NDVI se ve své práci věnovali i Massey et al. (2017), jejichž cílem bylo porovnání přesnosti dvou klasifikačních přístupů. První přístup vycházel z multitemporálního NDVI datasetu dat MODIS vytvořeného z let 2008 až 2012. Zde byla trénovací data zkombinována z let 2008, 2010, 2011 a 2012. Druhý přístupem bylo klasifikovat NDVI dataset zvlášť, a to v letech 2008, 2010, 2011, 2012. Každý roční dataset začínal v prosinci a končil v únoru dalšího roku (např. pro rok 2008 začínal dataset 27. prosince 2007 a končil 26. února 2009). V každém roce bylo zahrnuto celkem padesátpět NDVI snímků. Měření proběhlo na území Spojených států amerických, které je kompletně pokryto daty z vrstvy CDL. Data z CDL byla využita jako trénovací množiny ke klasifikaci a na základě této vrstvy bylo definováno osm tříd: kukuřice a sója dohromady, pšenice a ječmen dohromady, brambory, vaječná, bavlna, rýže, ostatní plodiny a půda ležící ladem. Na datech byla provedena klasifikace na základě „rozhodovacích stromů“ – *decision tree classification* a následně byly výsledky validovány. Oba přístupy dosáhly srovnatelné celkové přesnosti (75 % vs. 78 %), avšak nepatrně lepší přesnost vykazoval druhý klasifikační přístup.

Výzkum Jayawardhana, Chathurange (2015) se zaměřuje na zjištění fenologických parametrů plodin jako: start a konec zemědělské sezóny, délka sezóny, průměr okrajových hodnot, období středu sezóny, maximální hodnota NDVI během sezóny a amplituda). Studie proběhla na území Srí Lanky. Jako zdrojová data byl využit multitemporální NDVI komposit zahrnující roky 2000 až 2015 z dat MODIS o velmi malém prostorovém rozlišení 250 m. K extrakci fenologických parametrů byly použity metody Savitzky-Golay filtr a dvě metody vycházející z metody nejmenších čtverců. Z výsledků vyplývá, že odlišné typy plodin mají různá časová období, co se týče jejich stádií růstu. Tato stadia lze využít jako proměnné pro klasifikaci plodin a mapování v oblastech pěstování. Studie se ale nezmiňuje, které konkrétní plodiny byly klasifikovány, a ani jejich přesnost není známa. Na druhou stranu využití časové řady NDVI je účinné, což dokazují i studie předchozí.

Klasifikaci vybraných zemědělských plodin a vegetačních typů povrchu provedl také Vaudour et al. (2015). Studie se zaměřuje na klasifikaci plodin v brzké části zemědělské sezóny (měsíc duben) a porovnává data z multispektrálních družic SPOT4 (prostorové rozlišení 20 m) a Pléiades PHR-1A a PHR-1B (prostorové rozlišení 2 m). Obě družice disponují pásmy RGB a NIR. Autoři využili pixelovou klasifikaci pomocí metody SVM s polynomičnou kernelovskou

funkcí. Studie proběhla ve francouzském departmentu Yvelines a ke klasifikaci bylo zvoleno sedm tříd: pšenice ozimá, ječmen ozimý, ječmen jarní, řepka olejka, travnaté porosty, půda ladem a skupina ostatních plodin jako kukuřice a brambory). Klasifikován byl monotemporální dataset SPOT z 2. dubna 2013 a dataset z družice Pléiades z 3. a 24. dubna 2013. Dataset byl vždy tvořený čtyřmi spektrálními pásmy a snímkem NDVI. Zároveň byl vytvořen bitemporální dataset sdružující obě čtyři spektrální pásma a oba snímky NDVI z družice Pléiades z 3. a 24. dubna. Následně byly porovnány výsledky ze všech klasifikací. Nejpriznivější výsledky byly zaznamenány z datasetu družice SPOT4 z 2. dubna. Bitemporální dataset v tomto případě vykazoval nejnižší přesnost klasifikace. Studie ukazuje, že mapování v rané části sezóny vykazuje značný potenciál pro predikci výsevů plodin a detekci půdního obrábění plodin na jaře. Také odhaluje prostorové rozdíly raných fenologických stádií ozimých plodin, a právě tato stádia by mohla být klíčová pro přizpůsobení managementu oblastí s opožděným vývojem během vegetačního období.

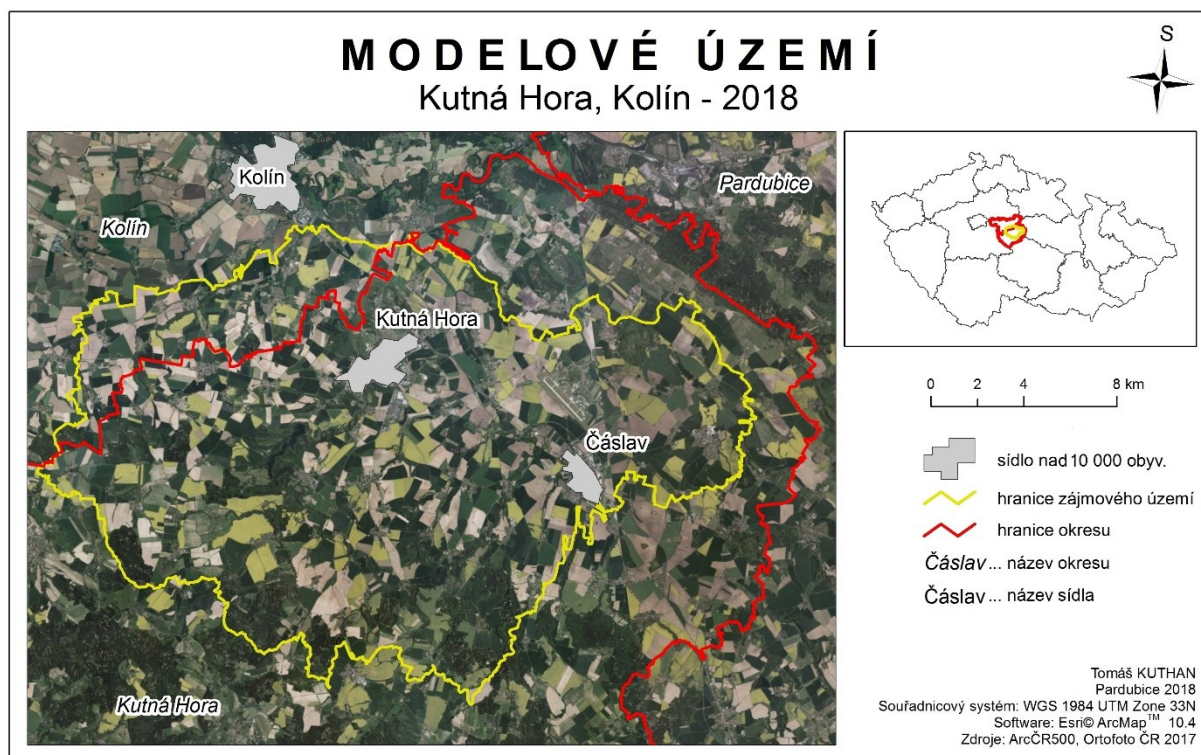
Výzkum od Vrieling et al. (2018) srovnává údaje z multispektrálních dat družice S-2 a osmi pozemních kamer Bushnell Trophy Cam Essential (model 119736), které mapují vegetační povrchy na ostrově Schiermonnikoog v Nizozemsku. K porovnání dat byl využit index NDVI ze snímků S-2 a index GCC vytvořený z dat pozemních kamer z dvou časových okamžiků a to 26. června 2016 a 7. března 2017. Z výsledků vyplývá, že porovnání fenologických parametrů z indexu NDVI a GCC ukazuje velké rozdíly mezi oběma indexy, navzdory jejich výrazné korelaci. Část těchto rozdílů by mohla být vysvětlena použitím rozdílných indexů a odlišným zobrazením úhlů pro satelitní a pozemní senzor. Studie také zmiňuje, že družice S-2 a satelity s podobně jemným rozlišením jsou vhodné pro poskytování prostorově detailních informací o vegetační fenologii plodin.

Z výše uvedených studií, či publikací vyplývá, že nejčastějším postupem pro klasifikaci zemědělských plodin je využití multitemporálního datasetu složeného buď z jednotlivých datasetů z různých termínů se spektrálními pásmy RGB a NIR nebo z indexů NDVI v průběhu roku, který velmi často definuje temporálně fenologické parametry. Ke zvýšení přesnosti klasifikace jsou velmi často využívána pásma RED EDGE, kterými právě S-2 disponuje. Mezi nejčastější metody klasifikace patří pixelová klasifikace založená na metodách SVM, ML nebo RF.

Pro data PlanetScope zatím žádné oficiální články a výzkumy ve spojitosti s klasifikací plodin neexistují. Práce by měla přinést nový poznatek ve smyslu, zdali data z družice PS poskytují lepší výsledky při klasifikaci plodin než data S-2.

3. Modelové území

Modelové území se nachází ve východní části Středočeského kraje na pomezí okresů Kolín a Kutná Hora. Území bylo vybráno z důvodu dostatečného výskytu druhů zemědělských plodin a také nízkého stupně zalesnění a urbanizovaných ploch. Území zahrnuje devadesát katastrů, pro něž SZIF poskytl prostorová data o rozmístění pěstování jednotlivých druhů plodin v roce



Obr. 18: Mapa modelového území
Zdroj: vlastní zpracování dat, 2018, ARCDATA PRAHA, 2016, ČÚZK, 2016

2017. Území má rozměry přibližně 25 x 15 km a celková rozloha činí 379,2 km². Mezi hlavní sídla nacházející se v území patří města Kutná Hora a Čáslav. Lesy zaujímají přibližně 9,8 %, urbanizované plochy 11,2 %, vodní plochy 0,4 % a zemědělské plochy – orná půda, louky a pastviny dohromady 78,6 %. Nejvyšším bodem jsou severozápadní svahy vrchu Březina s nadmořskou výškou 522 m n. m. nacházející se na jihozápadě území. Naopak nejnižším bodem je údolí Hořanského potoka s nadmořskou výškou 199 m n. m. na severu území. Dle relativní výškové členitosti spadá území s převýšením cca 300 m do kategorie členitých vrchovin. Na základě absolutní nadmořské výšky je území začleněno do nízkých vysočin (nadmořská výška 300 – 800 m n. m.). Nejznámějším vrcholem je vrch Kaňk (352 m n. m.) nacházející se severně od města Kutná Hora. Vrch se nachází v kutnohorském stříbrnosném revíru a téměř celé jeho území je protkáno pozůstatky starých důlních děl z minulých století.

Na jihovýchodním úbočí vrchu je lokalizována Národní přírodní rezervace Kaňk. Nejvodnatějším vodním tokem protékající územím je řeka Doubrava na východě území a nejrozsáhlejší vodní plochou je vodní nádrž Vrchlice u obce Malešov.

4. Data

Pro účely práce byla využita optická data družic Sentinel-2, PlanetScope, vektorová data z databáze LPIS, která poskytl SZIF (Státní zemědělský intervenční fond) a také vektorová data z digitální geografické databáze ArcČR 500.

4.1. Data Sentinel-2

Mise Sentinel-2 sdružuje v současné době 2 satelitní multispektrální družice a to Sentinel-2A a 2B. Obě družice vznikly na základě iniciativy evropského programu Copernicus realizovaného společně Evropskou komisí a Evropskou kosmickou agenturou (ESA). Obě družice jsou vybaveny senzorem MSI, který snímá povrch země v třinácti spektrálních pásmech (viz Tab. 1) s prostorovým rozlišením 10, 20 a 60 metrů v závislosti na daném pásmu. Výška



Obr. 19: Družice Sentinel 2-A
Zdroj: Satellite Imaging Corporation, 2017

orbitu družice je přibližně 786 km nad Zemí. Přínos obou družic je hlavně ve vysokém rozlišení s poměrně širokým záběrem (290 km) a také díky třem pásmům na okraji červeného viditelného spektra (RED EDGE), které je vhodné ke snímání stavu vegetace. Hlavní využití je v oblasti zemědělství, lesnictví, LU (*Land Use* – využití ploch v rámci LC) a LC (*Land Cover* – typy zemského povrchu) *changes*. Snímky družice Sentinel-2A jsou dostupné od listopadu 2015 a jejich perioda snímání stejného území je deset dnů. Společně se sesterskou družicí Sentinel-2B může samostatně opakovat snímání téhož území jednou za pět dní. V následujících letech jsou plánovány i družice Sentinel-2C a 2D. Data jsou poskytována ve dvou úrovních a po jednoduché registraci jsou volně stažitelná z webových stránek programu Copernicus (viz <https://scihub.copernicus.eu/dhus/#/home>). Úroveň 1C reprezentuje odrazivost na horní

hranici atmosféry (*Top of Atmosphere*) a úroveň 2A, která je již po korekcích, a reprezentuje odrazivost bez vlivů atmosféry na její dno hranici (*Bottom of Atmosphere*), tedy na povrchu Země (GISAT, 2018).

Tab. 1: Spektrální pásma družice Sentinel-2A a jejich rozlišení

pásmo	název pásma	prostorové rozlišení (m)	rozsah od (μm)	rozsah do (μm)
1	Coastal aerosol	60	0,433	0,453
2	Blue	10	0,4575	0,5225
3	Green	10	0,5425	0,5775
4	Red	10	0,65	0,68
5	Vegetation Red Edge I	20	0,6978	0,7125
6	Vegetation Red Edge II	20	0,7325	0,7475
7	Vegetation Red Edge III	20	0,773	0,793
8	NIR	20	0,7845	0,8995
8a	Narrow NIR	20	0,855	0,875
9	Water Vapour	60	0,935	0,955
10	Swir-Cirrus	60	1,365	1,395
11	SWIR I	20	1,565	1,655
12	SWIR II	20	2,1	2,28

Zdroj: GISAT, 2018

Pro účely práce bylo využito celkem jedenáct scén Sentinel-2 pro rok 2017 (viz Tab. 2). Protože zemědělská sezóna začíná pro ozimé plodiny přibližně na podzim předchozího roku, pro jařiny v období března a končí pro oba typy plodin na konci srpna (někdy i dříve), tak byly ke klasifikaci využity všechny dostupné bezoblačné scény (celkem šest scén) z období leden 2017 až srpen 2017. V období od září až do prosince, jsou již na polích vysévány nové plodiny a zpravidla platí, že každý rok se na stejném poli, či dílu půdního bloku jednotlivé plodiny střídají. Tím pádem lze využít pouze časovou řadu během jednoho roku. Pokud by byly do multitemporálního datasetu začleněny i scény starší než 30. srpen, tak ozimé plodiny v následujícím období již nepatrně vyklíčí a tím pádem by znehodnotily klasifikační výpočet, čili na jedné ploše by byly zjišťovány příznaky pro dvě plodiny, což by výrazně znehodnotilo výsledky. Z jedenácti scén bylo tedy ke klasifikaci využito šest scén a pro zjištění spektrálních průběhů pro každou plodinu v podobě grafů bylo využito všech jedenáct scén z období leden 2017 až prosinec 2017. Dále pro zjištění spektrálních příznaků byly využity termíny z let 2015 a 2016. Do grafů spektrálních křivek byly zahrnuty i scény starší než 31. srpen, jelikož jsem chtěl zjistit, jak moc se nově vyseté a vyklíčené ozimé plodiny projeví v hodnotách grafů, a jak moc se budou lišit od plodin, které se vyskytovaly na stejných plochách v období od ledna do

srpna za rok 2017.

Tab. 2: Využité termíny scén S-2

Data Sentinel-2	datum	klasifikace	spektrální příznaky
S-2A	01.01.2017	x	✓
S-2A	01.04.2017	✓	✓
S-2A	11.05.2017	✓	✓
S-2A	03.06.2017	✓	✓
S-2A	20.06.2017	✓	✓
S-2B	07.08.2017	✓	✓
S-2A	29.08.2017	✓	✓
S-2A	28.09.2017	x	✓
S-2A	01.10.2017	x	✓
S-2B	16.10.2017	x	✓
S-2A	07.12.2017	x	✓

4.2. Data PlanetScope

PlanetScope je multispektrální družice, poskytující VHR (*Very High Resolution*) data. Snímky jsou dostupné přibližně od poloviny roku 2016. Systém družic vznikl na základě iniciativy společnosti Planet. Její senzor disponuje čtyřmi pásmy RGB, NIR (viz Tab. 3), výška orbity je 400 km a opakovaný čas snímání stejného území dle oficiálních údajů je jeden den. Pro účely práce byla využita úroveň 3A s prostorovým rozlišením 3,125 m a čtyřmi spektrálními pásmy (Planet, 2018). Data PlanetScope je možné stáhnout ze serveru Planet z adresy <https://www.planet.com/explorer/>.

Tab. 3: Spektrální pásma družice PlanetScope

pásmo	název pásma	prostorové rozlišení (m)	rozsah od (μm)	rozsah do (μm)
1	Blue	3,125	0,455	0,515
2	Green	3,125	0,5	0,59
3	Red	3,125	0,59	0,67
4	NIR	3,125	0,78	0,86

Zdroj: Planet, 2018

Pro zjištění spektrálních příznaků plodin a k účelům klasifikace byly využity PS scény uvedené v Tab. 4. Ke klasifikaci jsem využil pouze sedm scén PS z toho důvodu, že jen ty pokrývaly téměř celé zájmové území (ve srovnání se scénami S-2 pokrývaly tyto PS scény více než 90 % území). Zbylé PS scény byly sice bezoblačné, ale pokrývaly velmi malou část území, a tak byly na nich analyzovány pouze spektrální příznaky.

Tab. 4: Využité termíny scén PS

datum	klasifikace	spektrální příznaky
01.04.2017	x	✓
11.05.2017	✓	✓
18.05.2017	x	✓
03.06.2017	✓	✓
15.06.2017	✓	✓
19.06.2017	x	✓
20.06.2017	x	✓
22.06.2017	✓	✓
31.07.2017	✓	✓
01.08.2017	✓	✓
05.08.2017	x	✓
10.08.2017	x	✓
29.08.2017	x	✓
30.08.2017	✓	✓
28.09.2017	x	✓
29.09.2017	x	✓
14.10.2017	x	✓
15.10.2017	x	✓
16.10.2017	x	✓
17.10.2017	x	✓
07.12.2017	x	✓

4.3. Ostatní datové zdroje

Klíčová data, která jsou v práci využita, jsou geometrická a atributová data s lokalizací zemědělských plodin z roku 2017. Jednalo se o data z databáze LPIS (SZIF, 2017a; SZIF, 2017b), která zahrnovala DPB – díly půdních bloků (vektorová data v souřadnicovém systému S-JTSK Krovak East North), čili polygony ploch, na kterých se pěstují jednotlivé plodiny a také tabulková data s přidělenými kódy DPB (SZIF, 2017c), které nesou informace o pěstované plodině (název, kód DPB, rozloha, ...). Poskytnuta byla také stejná data i pro roky 2015 a 2016. Ta byla využita pouze ke zjištění spektrálních příznaků, které byly zobrazeny v grafech. Dále byla využita volně dostupná data (administrativní jednotky) databáze ArČR500, z kterých vznikla hranice zájmového území, a poté byly vybrány průnikem všechny plochy, které toto území protínají. Také jsem využil webovou mapovou službu WMS ortofota ČR k vizuální interpretaci plochy zájmového území.

5. Metodika

5.1. Předzpracování dat

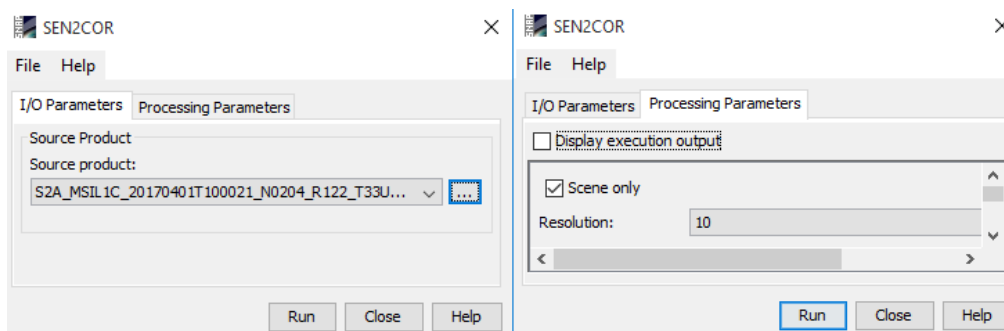
5.1.1. Atmosférické a radiometrické korekce

Efekty atmosféry způsobují, že naměřené hodnoty zářivých vlastností objektů na povrchu Země neodpovídají jejich vlastnostem ve skutečnosti. Hlavním cílem atmosférických korekcí je získání skutečných absolutních hodnot odrazivosti z hodnot naměřených radiometrem družice (Dobrovolný, 1998).

Song et al. (2004) popisuje, že pokud jsou multitemporální data v jednom datasetu a trénovací plochy jsou vybírány nad všemi pásmy, tak není potřeba provádět atmosférické korekce. Vzhledem k tomu, že veškeré korekce (atmosférické, geometrické korekce a korekce cirrus) pro data z družice Sentinel-2 jsem prováděl pomocí modulu Sen2Cor, tak jsem tuto otázku nemusel řešit, jelikož bylo potřeba provést i jiné korekce, než jen ty atmosférické a vše bylo zahrnuto ve zmíněném modulu. Stažená data družice PlanetScope použitá pro monotemporální klasifikaci byla korigována s využitím funkce *Quick Atmospheric Correction* v ENVI.

5.1.1.1. Sen2Cor

Sen2Cor je modul určený ke korekcím pro data Sentinel-2. Je součástí programu SNAP (více informací o tomto softwaru je popsáno v kapitole 5.4.1.) jako volně stažitelná extenze. Na vstupu je načten metadatový soubor (viz Obr. 20) propojený se snímkem každé scény Sentinel-2. Na základě tohoto souboru je vytvořeno nastavení, pomocí kterého jsou vypočteny hodnoty odrazivosti. Zahrnuje v sobě atmosférické, geometrické, radiometrické korekce a také korekce cirrus a výsledným produktem je deset pásem v rozlišení 10 a 20 m v tzv. úrovni 2A, která reprezentuje hodnoty odrazivosti na dolní hranici atmosféry (BOA).



Obr. 20: Nastavení modul Sen2Cor

5.1.2. Převzorkování, konverze a ořez dat

V dalším kroku bylo potřeba převzorkovat všechna pásma s rozlišením 20 m na rozlišení 10 m z toho důvodu, aby bylo možné vytvořit dataset s deseti pásmy o stejné velikosti pixelu 10 m. Tento krok byl opět proveden ve SNAPU pomocí metody *Resampling*. Takový postup je nezbytný, jelikož při spojování všech pásem s odlišnou velikostí pixelu v SW ENVI, je automaticky vypočtena velikost pixelu celého datasetu dle snímků s největší velikostí pixelu. Data byla poté vyexportována do formátu *.hdr, se kterým pracuje SW ENVI.

Následně bylo spojeno vždy všech deset pásem každého datasetu pomocí nástroje *Layer stacking* a poté byly všechny datasety spojeny dohromady. Vznikl tak multitemporální dataset s šesti scénami o deseti pásmech (celkem šedesát pásem) pro S-2 a sedmi scénami po čtyřech pásmech (celkem dvacet osm pásem) pro PS v období od 1. dubna do 30. srpna 2017. Na oba datasety byla v ENVI aplikována metoda PCA, aby došlo ke snížení dimenzionality dat. Ke klasifikaci byly použity první čtyři komponenty, které nesou nejvíce informací (viz Tab. 5). Druhým důvodem využití PCA byl záměr porovnat přesnost klasifikace dat s úpravou PCA a bez ní. Čtyři komponenty byly zvoleny z toho důvodu, že nesly mnohonásobně více informací než ostatní komponenty.

Tab. 5: Množství spektrální informace
prvních 4 komponent PCA

komponenta	PCA komponenty (%)	
	Sentinel-2	PlanetScope
1	44,0	65,8
2	25,9	15,2
3	8,6	12,1
4	5,5	3,5

5.1.3. Tvorba legendy

V práci byly klasifikovány tyto zemědělské plodiny: cukrovka, ječmen jarní, ječmen ozimý, kukuřice, pšenice jarní, pšenice ozimá, řepka ozimá (viz Tab. 6). Zbylé plodiny (vojtěška, brambory, úhor s kategorií U, ...) byly zařazeny do kategorie „ostatní plodiny“.

Tab. 6: Kategorie legendy

kategorie legendy
cukrovka
ječmen jarní
ječmen ozimý
kukuřice
ostatní
pšenice jarní
pšenice ozimá
řepka ozimá
trávy

protože se v území vyskytovaly ve velmi malé míře (dohromady tvořily cca 9 % rozlohy z lokalizovaných ploch plodin z databáze LPIS). Všechny uvedené plodiny jsou dle SZIF řazeny do kategorie standardní orná půda (R). Klasifikovány byly dále kategorie travní porost na orné půdě (G) a trvale travní porost (T) a to společně jako kategorie trávy. Do klasifikace nebyly zahrnuty další kategorie (vinice, chmelnice, ovocný sad, školka, rychle rostoucí dřeviny, jiná trvalá kultura, zalesněná půda, rybník mimoprodukční plocha, jiná kultura) z databáze LPIS, jelikož se práce zaměřovala především na zemědělské plodiny. Veškeré další nevegetační kategorie (zástavba, vodní plochy) SZIF neeviduje a tím pádem nebyly zahrnuty.

5.1.3.1. Cukrovka

Cukrovka (cukrová řepa) je zemědělská plodina pěstující se pro výrobu cukru. Pro cukrovarnické potřeby se pěstuje jeden rok. Vegetační období je dlouhé cca 190 – 200 dnů. Jedná se o náročnou zemědělskou plodinu, a proto je nutné ji věnovat pozornost po celou dobu jejího vegetačního období. Výsev probíhá v období od poloviny března do poloviny dubna. Sklizeň probíhá v říjnu a místy až do začátku prosince (HPS, 2018).

5.1.3.2. Ječmen jarní a ječmen ozimý

Ječmen jarní je obilovina patřící do kategorie jařin. Po pšenici ozimé je druhou nejčastěji pěstovanou plodinou. Primárním využitím ječmene jarního je krmivo pro dobytek. Dále se používá k výrobě sladu. Výsev probíhá co nejdříve z jara, a to zpravidla v půlce března. Vegetační doba činí cca čtyři měsíce a sklizeň probíhá na konci července nebo začátkem srpna v závislosti na plné zralosti zrna (Agromanual, 2018).

Jak už z názvu vyplývá, ječmen ozimý se řadí do ozimých plodin, které se na podzim vysejí, vyklíčí, přezimují zimu, na jaře pokračují ve vegetačním růstu a následně jsou sklizeny. V ČR je třetí nejmasověji pěstovanou obilovinou. Jeho využití je především pro krmné účely. Nejvhodnější doba setí je v druhé polovině září a sklizeň zpravidla probíhá nejdříve ze všech obilovin, a to v červenci (MENDEL, 2018).

5.1.3.3. Kukuřice

Kukuřice je jednoletá plodina dorůstající výšky od jednoho do tří metrů. Buď se pěstuje na zrno a má využití v potravinářském průmyslu, nebo na siláž (krmivo pro dobytek). Setí probíhá obvykle na přelomu dubna a května a sklizeň v září a říjnu. V případě, že je kukuřice využita jako krmivo, tak sklizeň probíhá cca o měsíc dříve (MENDEL, 2018).

5.1.3.4. Pšenice jarní a pšenice ozimá

Pšenice jarní ve srovnání s pšenicí ozimou je v našich podmínkách pěstována pouze jako

okrajová plodina. Nevýhodou jarní pšenice je kratší vegetační doba a menší kompenzační schopnost. Setí probíhá na přelomu března a dubna a sklizeň ke konci srpna (MENDELU, 2018).

Pšenice ozimá spadá do kategorie ozim a v ČR je nejmasověji pěstovanou obilovinou. Její využití je především v potravinářském průmyslu pro pekařské účely. Setí probíhá na přelomu října, ideálně do první půlky října a sklizeň na přelomu července a srpna (MENDELU, 2018).

5.1.3.5. Řepka ozimá

Řepka ozimá patří do kategorie olejnin. Ze všech plodin má nejdelší vegetační cyklus. Seta je ke konci srpna a na začátku září a sklízí se na konci července. Plody řepky se využívají v potravinářském průmyslu a také i jako biopaliva (MENDELU, 2018).

5.1.3.6. Travní porost na orné půdě

Travním porostem na orné půdě se rozumí zemědělsky obhospodařovaná orná půda využívaná k pěstování trav nebo jiných píceňin podle přímo použitelného předpisu Evropské unie upravujícího společná pravidla pro režimy přímých podpor v rámci společné zemědělské politiky na přírodních plochách nebo uměle vytvořených plochách, která je zahrnuta do střídání plodin uživatele půdy na dobu kratší než 5 let (MZe, 2015).

5.1.3.7. Trvale travní porost

Trvalými travními porosty a stálými pastvinami (společně uváděné jako „trvalé travní porosty“) je charakterizována půda využívaná k pěstování trav nebo jiných bylinných píceňin na přírodních (přirozený osev) nebo uměle vytvořených (umělý osev) plochách, která nebyla zahrnuta do střídání plodin v zemědělském podniku po dobu pěti a více let (MZe, 2015).

5.1.3.8. Úhor

Úhorem se rozumí zemědělsky obhospodařovaná orná půda ležící ladem, včetně ploch vyňatých z produkce v souladu s požadavky stanovenými v předpise Evropské unie, která byla v bezprostředně předcházejícím období nejméně po dobu 1 roku vedena v evidenci půdy s kulturou standardní orná půda, chmelnice, vinice, ovocný sad, rychle rostoucí dřeviny pěstované ve výmladkových plantážích, jiná trvalá kultura nebo školka. Úhor vznikne přírodním osemeněním, založením porostu plodiny nebo udržováním bez porostu. Úhor je nejméně jedenkrát ročně sečen, mulčován nebo pasen, včetně sečení nedopasků, a to v době od 1. června do 31. srpna příslušného kalendářního roku. Úhor bez porostu je udržován mechanickou kultivací nebo chemickými prostředky. Za plochu zemědělskou kultury úhor lze považovat plochu orné půdy, která není obdělávána za účelem produkce plodiny, ale tato plocha

je k dispozici pro rostlinnou výrobu, i když je ponechána ladem (MZe, 2015).

5.1.3.9. Ostatní

Mezi další plodiny vyskytující se v zájmovém území patří celkem dvacetsedm dalších druhů plodin (vojtěška, žito, oves, brambory konzumní, ...), které se ale vyskytují v minimálním množství a byly začleněny do kategorie ostatní. Do této kategorie spadá i úhor (U).

5.1.4. Tvorba klasifikační masky

Jelikož ENVI neumí klasifikovat scénu nad vektorovou maskou tak, aby byly výsledky korektní a nebyly do klasifikace zahrnuty pixely mimo klasifikační masku, tak bylo potřeba datasety oříznout. Vytvořil jsem klasifikační masku na základě vektorových dat SZIF, která obsahovala pouze polygony kategorie standardní orné půdy a dvou zmíněných travních porostů. Tím pádem jsou odmaskovány lesy, zástavba, vodní toky a ostatní typy ploch. Klasifikační maska byla pro všechny datasety dat z obou družic stejná. Stínů bylo ve snímcích minimální množství a odmaskovány nebyly. Oblačnost se ve snímcích, které byly použity ke klasifikaci, nevyskytovala, protože byly vybrány pouze bezoblačné scény.

Následně byly oba datasety z ENVI vyexportovány do formátu *.img a oříznuty klasifikační maskou v SW ArcGIS pomocí metody *Extract by mask*. Zpětně byly oba datasety otevřeny v ENVI a uloženy ve formátu *.hdr.

Analogickým postupem byly vytvořeny i multitemporální NDVI datasety (pro každou scénu byl vypočítán index NDVI a výsledné snímky byly spojeny do jednoho datasetu) a datasety vycházející z úpravy PCA jak pro S-2, tak pro PS, na kterých proběhne také klasifikace. Ke klasifikaci bylo připraveno celkem sedm datasetů (viz Tab. 7), čtyři datasety pro S-2 a tři pro PS z období od 1. dubna 2017 do 30. srpna 2017.

Tab. 7: Datasety využité ke klasifikaci

dataset	počet scén	počet pásem
1. multitemporální dataset Sentinel-2	6	60
2. multitemporální dataset Sentinel-2	6	24
multitemporální dataset PlanetScope	7	28
multitemporální dataset NDVI Sentinel-2	6	6
multitemporální dataset NDVI PlanetScope	7	7
PCA dataset Sentinel-2	6	4
PCA dataset PlanetScope	7	4

Hlavním důvodem, proč byly při klasifikaci využity netransformované multitemporální datasety se všemi deseti pásmy z každé scény S-2, je potenciál pásem RED EDGE a SWIR pro zvýšení přesnosti klasifikace plodin, který je zmiňován v rešeršní kapitole, viz Immitzer et al, (2016).

5.1.5. Tvorba trénovacích a validačních datasetů

Na podkladu dat LPIS z roku 2017 (plošné rozmístění klasifikovaných plodin reálně pěstovaných v modelovém území v roce 2017) bylo pro každou třídu vytvořeno několik rovnoměrně rozmístěných trénovacích ploch v závislosti na jejím procentuálním zastoupení v modelovém území (viz Tab. 8 a Obr. 21). Vzhledem k tomu, že dataset PS nepokrýval kompletně celé území datasetu S-2 (nebyla pokryta část na východě území, která činila cca 10 % rozlohy), tak trénovací množiny musely být přizpůsobeny a nepatrně se liší.

Tab. 8: Počty trénovacích ploch a jejich pixelů pro pixelovou klasifikaci

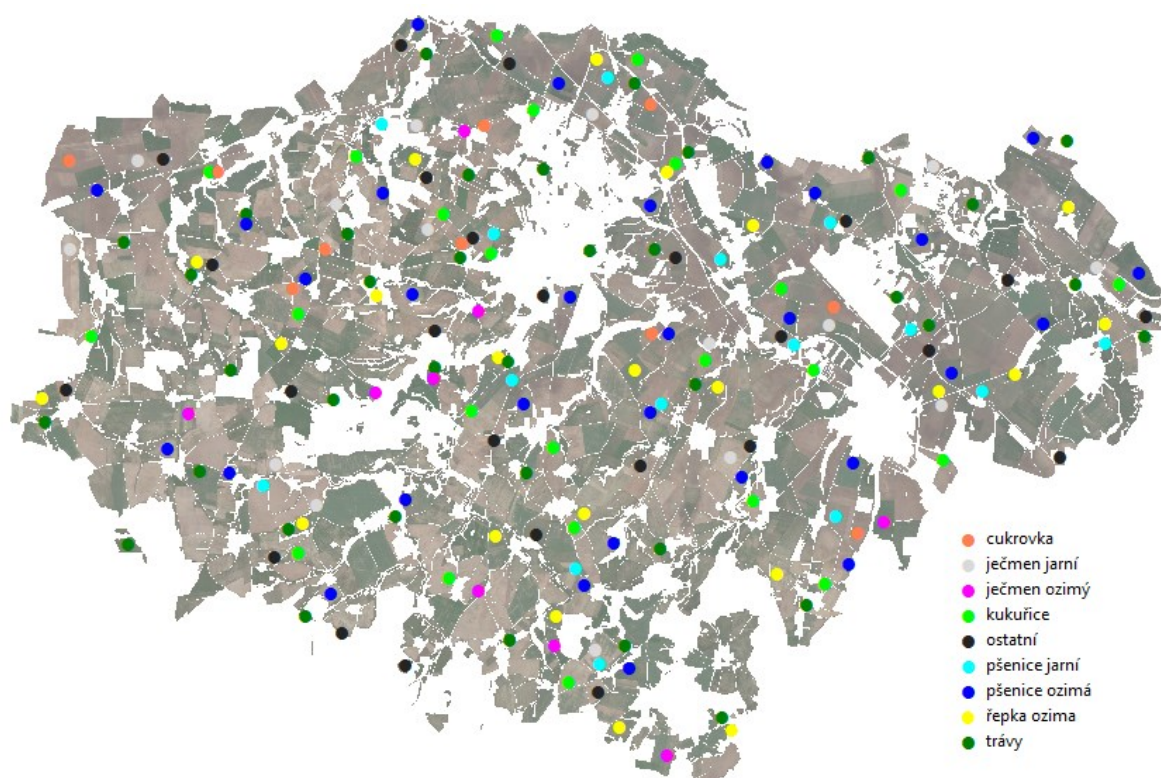
třída	Sentinel-2		PlanetScope	
	počet trénovacích ploch	počet pixelů	počet trénovacích ploch	počet pixelů
cukrovka	10	1908	10	17805
ječmen jarní	15	1958	14	17326
ječmen ozimý	9	1290	9	11667
kukuřice	24	2735	22	22167
ostatní	25	2071	22	16129
pšenice jarní	15	1588	13	12270
pšenice ozimá	30	3283	27	26027
řepka ozimá	22	3711	19	28238
trávy	37	1415	34	10892

Pro trénovací data jsem také testoval jejich odlišitelnost v SW ENVI pomocí nástroje *ROI Separability*. Testoval jsem trénovací data na všech spektrálních pásmech 1. a 2. multitemporálního datasetu S-2 a multitemporálního datasetu PS a také monotemporálně u třech zmíněných datasetů. Dá se očekávat, že trénovací plochy s větší separabilitou přinesou také lepší výsledky při klasifikaci. V průběhu testu byly vytvořeny kombinace jednotlivých tříd a byla posuzována jejich separabilita. Hodnoty se pohybují v rozmezí 0 – 2 pro každou dvojici tříd a čím větší hodnota tím lepší separabilita (Harris Geospatial Solutions, 2018). Úroveň separability jsem vyhodnotil na základě hodnoty průměru všech dvojic trénovacích ploch pro všechny multitemporální datasety a také pro monotemporální přístup (viz Tab. 9).

Tab. 9: Vyhodnocení míry separability pro trénovací množiny pro S-2 a PS

	1. multitemp. dataset S-2	2. multitemp. dataset S-2		multitemp. dataset PS
	průměrná míra separability			prům. míra separability
všechna pásma	1,9999996	1,9998608	všechna pásma	1,9991259
01.04.2017	1,7703125	1,4166710	11.05.2017	1,6033424
11.05.2017	1,9363471	1,7093808	03.06.2017	1,5736430
03.06.2017	1,9565756	1,6781683	15.06.2017	1,5795103
20.06.2017	1,9532978	1,8039582	22.06.2017	1,5245493
07.08.2017	1,8901439	1,6961546	31.07.2017	1,6024135
29.08.2017	1,8015181	1,4517370	01.08.2017	1,5374237
			30.08.2017	1,4035322

Nejlepší míry separability dosáhly všechny multitemporální datasety ve srovnání s monotemporálním přístupem. U datasetů S-2 byl úspěšnější 1. multitemporální dataset s vlivem pásem RED EDGE. Nejlepší separability u monotemporálního přístupu vykazuje termín 3. 6. 2017. Klasifikace v tomto termínu by teoreticky měla vykazovat nejlepší výsledky oproti jiným termínům v průběhu roku. PS vykazuje horší separabilitu než S-2 a nejvhodnějším termínem pro monotemporální klasifikaci PS by měl být dle separability datum 11. 5. 2017.



Obr. 21: Rozmístění trénovacích ploch pro pixelovou klasifikaci S-2

Zbytek ploch plodin z databáze LPIS v modelovém území (viz Tab. 10) reprezentující každou kategorii bylo zahrnuto do validačních ploch, které byly velmi početné a tím pádem, poskytují mnohem přesnější kontrolu klasifikace. Na validační plochy byl aplikován záporný

buffer o velikosti 10 m (jak pro snímky S-2, tak pro PS) z důvodu, aby při validaci nebyly zahrnuty hranové pixely ploch, které jsou oproti pixelům umístěných ve středu plochy vysoce heterogenní a vlivem mísení pixelů na hranici ploch vykazují jiné spektrální hodnoty.

Tab. 10: Počty validačních ploch a počty jejich pixelů – pixelová klasifikace

třída	Sentinel-2		PlanetScope	
	počet validačních ploch	počet pixelů	počet validačních ploch	počet pixelů
cukrovka	14	27711	14	275591
ječmen jarní	52	42787	47	371084
ječmen ozimý	14	9826	14	96226
kukuřice	81	71822	79	666614
ostatní	99	51739	92	467997
pšenice jarní	30	11095	29	101366
pšenice ozimá	251	235144	234	2054284
řepka ozimá	97	111791	86	909084
trávy	524	50949	511	424808

Na základě segmentace obrazu nad multitemporálními daty S-2 a PS byly pro objektovou klasifikaci vytvořeny trénovací objekty (viz Tab. 11).

Tab. 11: Počty trénovací a validační plochy pro objektovou klasifikaci

třída	Sentinel-2		PlanetScope	
	počet trénovacích ploch	počet validačních ploch	počet trénovacích ploch	počet validačních ploch
cukrovka	12	14	14	14
ječmen jarní	18	52	14	48
ječmen ozimý	14	13	20	13
kukuřice	32	79	35	77
ostatní	32	98	29	92
pšenice jarní	19	30	17	29
pšenice ozimá	40	251	40	231
řepka ozimá	61	96	43	84
trávy	60	521	63	508

Z jednotlivých segmentů byly vytvořeny trénovací plochy. Pro každou třídu byl vždy větší počet ploch než pro pixelovou klasifikaci, jelikož jsem se snažil vytvořit plochy tak, aby jejich rozměry při segmentaci odpovídaly plochám ve skutečnosti, což se mi poměrně vydařilo (viz Obr. 22). Nicméně ne vždy platilo pravidlo, že jedna plocha ve skutečnosti se rovnala jedné trénovací ploše. Určité plochy byly tvořeny i více segmenty, tak aby se zachoval tvar ploch vůči skutečnosti. Někdy se jednalo pouze o jednotky pixelů, které tvořily velmi malé segmenty. Některé objekty také zasahovaly i do validačních ploch (u každé třídy cca jedna plocha), a tak musely být tyto validační plochy nepatrně upraveny, popřípadě smazány. Občas se také stalo, že některé trénovací plochy nepatrně přesahovaly hranice skutečného tvaru plochy z vektorových dat (z celkového množství trénovacích ploch cca čtyři plochy). Z více jak 99 % byly ale trénovací i validační plochy pro pixelovou i objektovou klasifikaci stejné.

5.2. Analýza dat

5.2.1. Analýzy spektrálních příznaků

Pro jednotlivé třídy byly na základě trénovacích množin na 1. a 2. multitemporálním datasetu S-2 zjištěny hodnoty spektrálních pásem (*mean* hodnota každého pásma), vedoucí ke zjištění odlišitelnosti trénovacích množin pro jednotlivé kategorie legendy v určitých časových intervalech. Dále byl k hodnocení průběhu spektrálního projevu plodin v průběhu sezóny využit vegetační index NDVI. Účelem vegetačních indexů je zmenšení spektrálního rozsahu dat na jednu hodnotu, která bude vystihovat zkoumanou vlastnost vegetace (Dobrovolný, 1998), v případě NDVI je to hustota vegetace/pokryvnost. Další výhodou je, že analyzujeme jednu hodnotu, což je jednodušší v porovnání s vyhodnocováním více samostatných pásem. Statistiky pro průběh DN hodnot a NDVI jsou interpretovány v kapitole Výsledky (viz kapitola 6).


5.2.2. Klasifikace

Ke klasifikaci vybraných tříd byly na vybrané datasety aplikovány pixelová a objektová klasifikace (objektová pouze na oba multitemporální datasety S-2 a multitemporální dataset PS). Při klasifikaci PCA nebo NDVI datasetů bylo dosaženo výrazně menší celkové přesnosti, a tak na tyto datasety již nebyla aplikována objektová klasifikace. Na základě rešerše literatury a zdrojů (viz kapitola 2) byly vybrány *Maximum Likelihood* a SVM jako metody pro pixelovou klasifikaci.

Obě metody jsou rozdílné. Metoda ML na rozdíl od SVM vyžaduje tzv. normální rozdělení trénovacích dat, které je charakterizováno Gaussovou křivkou (Jensen, 2005). Trénovací množiny reprezentované počty pixelů by měly po zanesení do grafu mít tvar Gaussovy křivky. Z trénovacích množin (konkrétně z počtu pixelů pro každou třídu) byly pro oba multitemporální datasety (1. multitemporální dataset S-2 a multitemporální dataset PS) spočítány směrodatné odchylky, které byly potřeba pro spočítání normálního rozdělení pravděpodobnosti. Dále jsem zvolil intervaly (pro S-2 -1000 až 800 a PS -10000 až 8000 tak, abych po propočítání se směrodatnou odchylkou mohl využít koeficienty z distribuční tabulky), na kterých bylo spočítáno normální rozdělení dat. Pomocí hodnot z distribuční tabulky normálního rozdělení (ČVUT, 2018) dat jsem vypočítal jednotlivé hodnoty normálního rozdělení a nakonec vynásobil příslušným koeficientem tak, aby se hodnoty přiblížily hodnotám počtů pixelů pro jednotlivé třídy (viz Graf 1). Z obou grafů vidíme, že data podléhají normálnímu rozdělení dat (viz Gaussova křivka oranžovou barvou). U dat PS je křivka výrazná, u dat S-2 je křivka plošší, ale tvar Gaussovy křivky stále má. Normalitu rozložení dat jsem hodnotil také vizuálně pro

jednotlivá pásma z histogramů trénovacích množin.

Graf 1: Normální rozdělení trénovacích dat reprezentované Gaussovou křivkou



Výchozími datasey pro pixelovou klasifikaci byly 1. a 2. multitemporální dataset Sentinel-2 a multitemporální dataset PS, na které byly aplikovány obě metody (ML a SVM) s různými nastaveními (nastavení *Probability Threshold* u ML a *Degree of Kernel Polynomial*, *Pyramid Levels* ,... pro SVM). Metoda s nejvyšší přesností (hodnocena dle parametru celkové přesnosti v procentech) byla zvolena jako hlavní pro zbylé datasey (viz Tab. 7) a též pro monotemporální způsob klasifikace. Následně byl vybrán jeden dataset, který dosáhl nejvyšší celkové přesnosti a ten byl srovnán s výsledky objektové klasifikace. Současně byl aplikován monotemporální přístup (metoda ML) na všechny termíny z 1. a 2. multitemporálního datasetu S-2 (vliv pásem RED EDGE) a multitemporálního datasetu PS a byla vyhodnocena otázka, zdali je vhodnější multitemporální přístup nebo klasifikace z jednoho časového období.


5.2.2.1. Pixelová klasifikace

V SW ENVI byla provedena řízená pixelová klasifikace metodou Maximum likelihood s defaultním nastavením klasifikátoru *Probability threshold: None*). Zkoušel jsem nastavovat pro jednotlivé třídy prahové hodnoty (od 0,95 do 0,75) pro zařazení pixelů do jednotlivých tříd, nicméně výsledky vykazovaly vždy menší celkovou přesnost klasifikace než při defaultním nastavení. Klasifikace proběhla pro devět zmíněných tříd (viz Tab. 6) a výsledek byl validován pomocí validačních množin (viz dále).

Na stejné datasey (1. a 2. multitemporální dataset S-2 a multitemporální dataset PS) jsem aplikoval metodu *Support vector machine* s funkcí RBF a opět defaultním nastavením. Dále jsem testoval i ostatní funkce metody SVM a to *linear*, *polynomial* a *sigmoid*, ale vykazovaly nepatrně menší (v průměru o 2 – 3 %) celkovou přesnost výsledků klasifikace.

5.2.2.2. Objektová klasifikace

Objektově orientovaná klasifikace byla aplikována na tři datasety (1. a 2. multitemporální dataset S-2 a multitemporální dataset PS). V SW ENVI byl využit nástroj *Example Based Feature Extraction Classification* s následujícím nastavením. Jako algoritmus segmentace byla



Obr. 22: Segmentace při objektové klasifikaci s danými parametry, v L S-2, v P PS

vybrána metoda *Edge* s měřítkovým parametrem *Scale Level* o hodnotě 70 pro S-2 a 75 (při testování takto zvolené parametry vykazovaly nejlepší výsledky) pro PS (čím větší hodnota na intervalu 0 – 100, tak tím větší objekty). Jako algoritmus spojování byla vybrána metoda *Full Lambda Schedule* s parametrem *Merge Level* o hodnotě 90 pro S-2 a 95 (opět při testování takto zvolené parametry vykazovaly nejlepší výsledky) pro PS (čím větší hodnota na intervalu 0 – 100, tím větší propojení objektů). Byla vybrána všechna pásma z datasetu, ta byla klasifikována na základě spektrálních, texturních a prostorových příznaků (např. *Spectral Mean*, *Spectral Std*, *Spectral Min*, *Spectral Max*, *Texture Range*, *Texture Mean*, *Texture Variance*, *Texture Entropy*, *Area*, *Length*, *Compactness*, *Convexity*,...) a také ponechány defaultní hodnoty pro každou ze tří metod (KNN, SVM, PCA) objektově orientované klasifikace. Tyto tři metody byly otestovány a byl vyhodnocen výsledek s nejvyšší celkovou přesností, který byl porovnán s výsledky pixelové klasifikace.

Postup pro výběr nejvhodnějšího výsledku objektové klasifikace byl následující. Na všechny multitemporální datasety (dva pro S-2 a jeden pro PS) byla aplikována objektová klasifikace – nástroj *Example Based Feature Extraction Classification* a byl vyhodnocen nejlepší výsledek, který zodpověděl hlavní hypotézu, zdali je vhodnější pixelový nebo objektový přístup pro klasifikaci vybraných zemědělských plodin.

5.3. Validace dat

Veškerá data byla validována s využitím kontrolních množin (viz Tab. 10 a Tab. 11). Byla vypočítána chybová matice v SW ENVI (nástroj *Confusion Matrix Using Ground Truth ROIs*). K validaci byly využity parametry: celková přesnost (CP), koeficient Kappa, zpracovatelská přesnost (ZP), uživatelská přesnost (UP), chyba z opomenutí (CHO) a chyba z nesprávného zařazení (CHZ).

Dále byla využita validace, při které došlo k porovnání rozloh jednotlivých tříd v procentech. Byl porovnán skutečný stav z databáze LPIS (pouze na plochách, u kterých jsem s jistotou věděl, jaká plodina se zde přesně pěstovala) a výsledky nejlepších klasifikací.

5.4. Použitý Software

5.4.1. SNAP

Software SNAP neboli Sentinel Application Platform (použita verze šest) je volně dostupný program (<http://step.esa.int/main/toolboxes/snap/>), který vznikl jako rozhraní pro úpravu dat z družic Sentinel, SMOS, Radarsat a PROBA-V, které vznikly na základě iniciativy společnosti ESA. Program má předdefinované základní nástroje pro úpravu snímků DPZ a také poskytuje možnost instalace tzv. toolboxů, které mají rozšířené nástroje dle typu zpracovávaných dat. Do programu byl nainportován Sentinel-2 Toolbox poskytující nástroje pro úpravu snímků Sentinel-2 a také modul Sen2Cor, sloužící pro atmosférické a radiometrické korekce. Velkou nevýhodu tohoto SW vidím v nízké rychlosti zpracování dat, která je zcela nevyhovující a k samotné analýze dat bylo potřeba zvolit jiný SW. SNAP byl využit pouze ke korekcím a převzorkování snímků S-2.

5.4.2. ENVI

Komerční SW ENVI je produkt dodávaný americkou společností Harris Geospatial Solutions, Inc, která poskytuje služby v oblasti zpracování dat DPZ. V ENVI nalezneme kompletní sadu nástrojů pro předzpracování, analýzu, vizualizaci a sdílení dat DPZ. ENVI je speciálně navrženo pro práci s družicovými snímky, podporuje většinu současných družicových systémů a také je možná práce s vektorovými daty a databází. V rámci práce byla využita verze 5.3. SW ENVI byl využit především pro klasifikaci a validaci dat S-2 a PS.

5.4.3. ArcGIS for Desktop

ArcGIS je komerční geografický informační systém vyvinutý firmou Esri. Tento SW je

určený pro práci s prostorovými daty. Data můžeme vytvářet, spravovat, analyzovat, najít v nich prostorové vztahy a také je přehledně vizualizovat. S daty můžeme např. provádět překryvné, vzdálenostní, síťové analýzy či analýzy povrchů. Součástí programu je několik extenzí (*3D Analyst*, *Spatial Analyst*, ...), které obsahují různé analytické nástroje. ArcGIS for Desktop je dostupný ve třech úrovních, a to v ArcView, ArcEditor a také ArcInfo, který poskytuje tvorbu nových databází a dat a kompletní sadu nástrojů pro pokročilé analýzy dat. Každý ze tří desktopových produktů je tvořen aplikacemi ArcMap (základní rozhraní pro analýzu a vizualizaci dat), ArcCatalog. Pro analýzu dat GIS byů využíván soubor nástrojů obsažený v uživatelském rozhraní ArcToolbox. SW ArcGIS (ArcMap) byl využit k vizualizaci výsledků klasifikací v podobě mapových výstupů.

6. Výsledky

Kapitola zahrnuje výsledky analýzy spektrálních příznaků jednotlivých klasifikačních tříd a dále výsledky klasifikací pro data Sentinel-2 a PlanetScope.

6.1. Analýzy spektrálních příznaků klasifikačních tříd

Výsledky analýzy sezónního průběhu spektrálního projevu jednotlivých tříd jsou hodnoceny zejména na základě grafů. V grafech jsou pro S-2 i PS zaneseny pro hodnoty NDVI v průběhu sezóny a pro S-2 DN hodnoty (osa y: pro S-2 byly DN hodnoty získány pronásobením hodnoty odrazivosti koeficientem 10000) pro pásma RGB a NIR a pro S-2 i PS index NDVI (hodnota na ose y) pro každý časový termín (osa x). Pro PS byla k dispozici delší časová řada, a protože všechny termíny nebyly z časových důvodů atmosféricky korigovány, taky bylo hodnocení provedeno pouze na základě NDVI. Pro každou třídu byly nejprve porovnány hodnoty NDVI pro S-2 a PS ve stejných termínech, nebo alespoň v termínech nejvíce podobných (např. S-2 z 1. 10. a PS z 29. 9.). Dále byly popsány časové řady pro PS s hodnotami NDVI, kterou tvoří celkem dvacet jedna termínů v průběhu roku 2017. Pro S-2 nebyla taková časová řada dostupná z důvodu přílišné oblačnosti. Na základě grafů byly popsány rozdíly mezi ozimými plodinami a jařinami (jejich hlavní vegetační období, období sklizně, ...) a také rozdíly mezi jednotlivými plodinami, které jsou v určitých termínech od sebe alespoň trochu odlišitelné.

Časová osa v grafech reprezentuje termíny od ledna do prosince 2017. V úvahu je potřeba brát ale fakt, že konec hlavní zemědělské sezóny je přibližně datován ke konci srpna, kdy jsou téměř všechny plodiny sklizeny (výjimkou je např. cukrovka, která se někdy sklízí až v prosinci) a půda je poté postupně upravena pro další setí, a to buď již na podzim, nebo následující rok na jaře. Veškeré časové termíny z pozdějších termínů než 31. 8. je potřeba brát s rezervou (viz poslední odstavec v kapitole 4.1.), jelikož většinou už neukazují skutečné hodnoty dané plodiny, ale mohou už reprezentovat hodnoty holé půdy nebo jiných plodin vysetých po tomto datu, protože se prakticky každý rok na stejné ploše pěstuje jiná plodina (hlavně setí následných ozimých plodin). I přesto jsem tyto termíny v grafech zanechal, abych zjistil, k jaké změně dojde. Dá se předpokládat, že tyto hodnoty budou celkově nižší z důvodu minimálního množství vegetace na dané ploše po sklizni.

U třídy ostatní nebyly spektrální příznaky zjišťovány, resp. NDVI zjišťovány, jelikož se jedná o směsici více plodin a hodnoty by byly výrazně zkreslené a nerelevantní.

6.1.1. Obecné znaky tříd

Při porovnání grafů můžeme vidět podobné průběhy NDVI pro data S-2 a PS. Čím menší rozdíl mezi pásmem RED a NIR, tím méně vegetace se v daném místě nachází. Na indexu NDVI se to pak projeví velmi nízkou hodnotou. Tento jev se dá vysledovat i z grafů NDVI u některých plodin, např. ječmen jarní a ozimý v období ke konci srpna, kdy proběhne sklizeň a půda je na pár dnů či týdnů holá nebo téměř holá a hodnoty NDVI jsou velmi nízké. Oproti tomu velká hodnota indexu NDVI indikuje výrazný výskyt vegetace.

Výrazný nárůst vegetace je také charakterizován vysokou hodnotou v pásmu NIR, jelikož zde odpovídá vlnová délka pásmu tzv. vysoké odrazivost (neboli buněčné struktury), která se projevuje ve vlnových délkách od 0,7 až 1,3 mikrometrů, což je typické pro pásmo NIR.

Obecně platí, že ozimé plodiny (řepka ozimá, pšenice ozimá, ječmen ozimý) dosahují mnohem vyšších hodnot ve všech pásmech v období leden až červen. Tím že jejich výsev probíhá již na podzim předchozího roku, tak také dříve vyklíčí a poté dříve na jaře pokračují v růstu než jařiny.

Oproti tomu jařiny (kukuřice, cukrovka, ječmen jarní, pšenice jarní) dosahují nižších hodnot v první půlce roku a poté jejich hodnoty postupně stoupají, nepatrnou výjimkou je ječmen jarní, který nejvyšších hodnot dosahuje v první půlce roku a jeho spektrální projev se v průběhu sezóny podobá spektrálnímu projevu ječmene ozimy. Přestože oba typy ječmenů mají podobný průběh spektrální křivky, tak nejvíce odlišitelné období dle grafů je pro ně leden až duben.

Jedinou nevýhodou využití časové řady dat patrnou z grafů je poměrně dlouhá časová mezera mezi termínem 22. 6. a 31. 7. Právě toto období může být klíčové z hlediska rozpoznání rozdílů mezi jednotlivými plodinami, nicméně snímky nebyly dostupné z důvodu vysoké oblačnosti. Tento problém jsem se snažil nahradit kombinovaným grafem (viz kapitola 6.1.10.) pro data S-2 z let 2015, 2016 a 2017, který výrazně pomohl popsat a přesněji určit vegetační změny v období od 22. 6. do 13. 7.

Z interpretace všech grafů jsem se také snažil definovat jednotlivé fenologické fáze (viz kapitola 6.3.) pro každou plodinu. Vymezil jsem 1) období setí, 2) období klíčení a růstu, 3) období hlavní vegetační fáze s vegetačním vrcholem (ten je definován jako termín s nejvyšší hodnotou NDVI) a 4) období sklizně.

Období setí bylo jasně definovaná dle obecných termínů pro každou třídu. Po něm hned následovalo období klíčení a růstu. Hranice mezi tímto obdobím a obdobím hlavní vegetační fáze byla určena pro S-2 u grafů hodnotou NDVI nad 0,8 a u grafů DN hodnot cca desetinásobkem odrazivosti v pásmu NIR vůči pásmu RED. Pro PS u grafů NDVI byla hranice nad 0,5. Hranice mezi obdobím hlavní vegetační fáze a obdobím sklizně byla určena pro S-2 u grafů NDVI pod hodnotu 0,4 a u grafů DN hodnot výrazným nárůstem pásma RED vůči pásmu NIR (pásmo RED dosahuje cca třikrát menších hodnot než pásmo NIR) a také celkově nárůstem pásem BLUE a GREEN (vzestupné hodnoty v pořadí pásem BLUE, GREEN a RED). Pro PS u grafů NDVI určovala hranici hodnota 0,2.

Fenofáze byly hodnoceny pro data S-2 a PS z důvodu porovnání, zdali se na různých datech spektrálně projevují plodiny podobně, či odlišně. Výsledky jsem poté porovnal s fenofázemi definovanými v literatuře – viz kapitola 2 – Rešerše a úvod do problematiky a také s obecnými termíny zemědělské sezóny pro každou sledovanou plodinu.

6.1.2. Cukrovka

Graf 2: Skupina grafů spektrálních projevů a NDVI pro třídu cukrovka



Z grafů vidíme, že cukrovka má velmi dlouhé vegetační období (viz grafy s indexem NDVI). Setí probíhalo od poloviny března do poloviny dubna, sklizeň pak v říjnu, někdy i na počátku prosince. Z grafů DN hodnot pro S-2 vidíme, že minimálně do konce května rostlina

pouze pomalu klíčila (stoupající NDVI hodnoty od dubna do půlky června) a plně vzrostlá byla ke konci června (vysoké NDVI hodnoty a vysoký rozdíl mezi pásmy RED a NIR). Vegetační období bylo velmi dlouhé, což dokazuje graf NDVI s hodnotami od 0,5 do 0,6, které trvají až do půlky října. Poté již proběhla sklizeň (pokles hodnot NDVI, malý rozdíl mezi pásmy RED a NIR).

6.1.3. Ječmen jarní

Graf 3: Skupina grafů spektrálních projevů a NDVI pro ječmen jarní



Ječmen jarní je typická jařina, u které probíhá výsev co nejdříve z jara, a to koncem března. Má poměrně rychlý růst a již začátkem května byla plodina plně vzrostlá, poté následovalo velmi krátké hlavní vegetační období (půlka května – konec června) a pak proběhla sklizeň (téměř nulové hodnoty NDVI, vysoké hodnoty RGB a nízké hodnoty NIR, které značí téměř holou půdu po sklizni). Od začátku října pravděpodobně proběhlo setí nové ozimové plodiny (vzestup NDVI hodnot, pokles hodnot RGB a větší rozdíl mezi pásmy NIR a RED u S-2 než v období od července do srpna), nebo půda zarostla malým množstvím vegetace a strojově upravena byla až později na začátku listopadu nebo až v březnu následujícího roku.

6.1.4. Ječmen ozimý

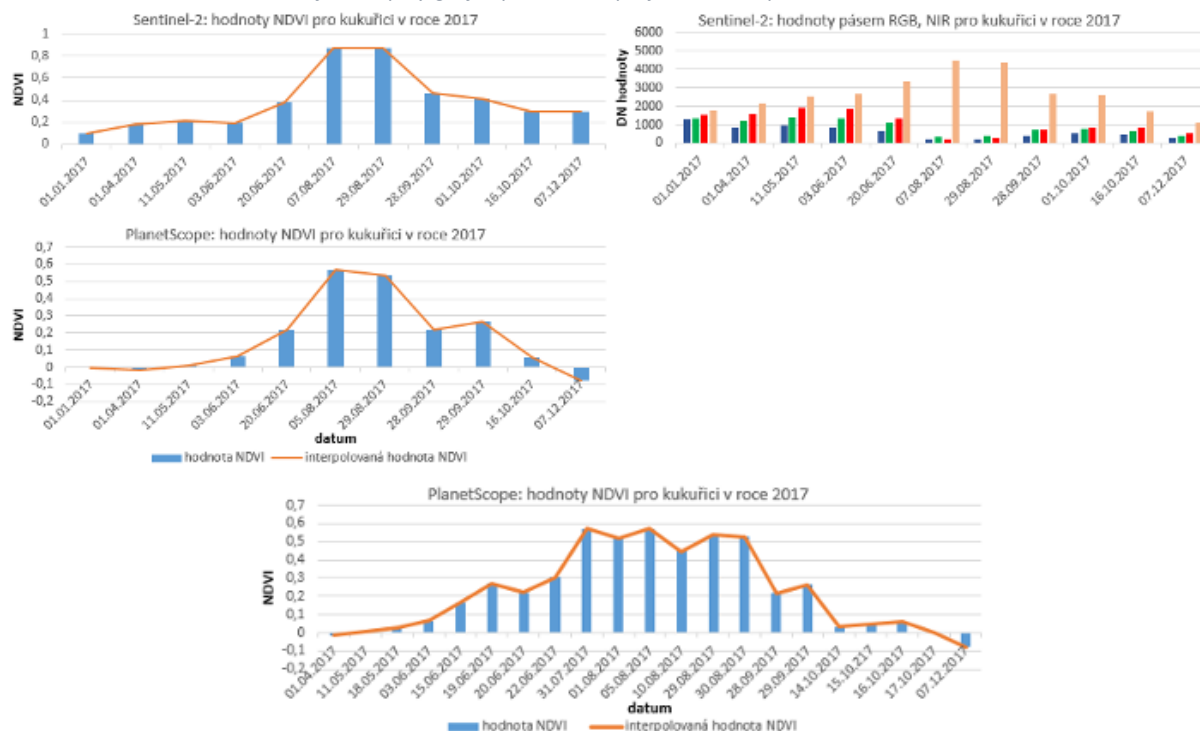
Graf 4: Skupina grafů spektrálních projevů a NDVI pro ječmen ozimý



Ječmen ozimý má velmi podobný spektrální projev jako ječmen jarní. Nicméně zásadní rozdíl je v tom, že vzrostl mnohem dříve po nástupu jara, a také mnohem dříve začala jeho hlavní vegetační fáze (cca o měsíc dříve než u ječmene jarního), která je datována dle grafů od konce dubna. Období sklizně bylo dle grafů totožné.

6.1.5. Kukuřice

Graf 5: Skupiny grafů spektrálních projevů a NDVI pro třídu kukuřice



Plodina kukuřice má výrazně posunuté období výsevu. Zpravidla je to přelom dubna a května. Poté začíná klíčit. Z hodnot NDVI vidíme, že první projevy rozvoje vegetace se objevily ke konci května, kdy stoupaly hodnoty NDVI, ty rostly až do začátku srpna. Poté následovala hlavní vegetační fáze (cca 1 měsíc – celý srpen) a začátkem září byla plodina sklizena (pokles NDVI hodnot a malý rozdíl mezi pásmem RED a NIR u S-2). Od 28. 9. do 17. 10. byla půda na základě grafů téměř holá.

6.1.6. Pšenice jarní

Graf 6: Skupiny grafů spektrálních projevů a NDVI pro třídu pšenice jarní



Pšenice jarní má velmi podobný spektrální průběh jako ječmen jarní. Nicméně při srovnání s Grafem 3 pro ječmen jarní vidíme, že fáze růstu začala u pšenice jarní o něco později a začátek hlavní vegetační fáze byl posunut cca o polovinu měsíce (částečně je to vidět z grafu DN hodnot pro S-2 – termíny 11. 5.). Projevilo se to též na hodnotách NDVI (termín 11. 5.), kde pšenice jarní dosahuje nepatrně nižších hodnot, nicméně pšenice a ječmen jarní mají ze všech plodin nejvíce shodně spektrální projevy. Sklizeň proběhla koncem července (pokles NDVI hodnoty) a následně došlo buď k setí nové plodiny, nebo výraznému nárůstu přirozené vegetace, jelikož grafy v tomto období vykazují vysoké NDVI hodnoty a vysoký rozdíl mezi pásmy RED a NIR.

6.1.7. Pšenice ozimá

Graf 7: Skupina grafů spektrálních projevů a NDVI pro třídu pšenice ozimá



Stejně jako porovnání obou druhů ječmenů, tak i v případě pšenice jarní i ozimé jsou spektrální projevy téměř totožné. Plodina velmi brzy vykvetla a již na počátku května nastalo období hlavní vegetační fáze, která trvala do začátku července a poté následovala sklizeň. Nepatrným rozdílem by mohly být hodnoty NDVI, které u pšenice ozimé dříve klesají, a to od začátku do konce června, což je pravděpodobně dáno dozráváním a změnou bravy (snížením množství chlorofylu) dané plodiny.

6.1.8. Řepka ozimá

Graf 8: Skupina grafů spektrálních projevů a NDVI pro třídu řepka ozimá



Řepka ozimá se projevuje nejvyššími hodnotami pásma NIR (grafy DN hodnot pro S-2) ze všech zmiňovaných plodin (období od poloviny května do poloviny června). Již od dubna byla plodina téměř vzrostlá a přibližně v polovině až koncem dubna (viz Graf 12 a Graf 13) nastalo hlavní vegetační období, které trvalo až do konce června a poté byla plodina postupně sklízena. Snížení NDVI v květnovém termínu způsobilo s největší pravděpodobností kvetení.

6.1.9. Trávy

Graf 9: Skupina grafů spektrálních projevů a NDVI pro třídu trávy



Třída trávy se od ostatních plodin liší konstantním projevem v průběhu sezóny. Významné poklesy NDVI v červnu a srpnu jsou způsobeny kosením trávy. Nikdy však nedochází k obnažení půdy, a tudíž poklesu NDVI prakticky na nulu právě proto, že travní porost je trvalý. Nejvýraznější vegetační období z hlediska produkce chlorofylu je dle grafů v květnu (nejvyšší NDVI hodnoty a také NIR hodnoty).

6.1.10. Srovnání NDVI hodnot pro S-2 a PS

Porovnání NDVI hodnot pro data S-2 a PS v jednotlivých termínech (viz Graf 10) poskytlo velmi dobré zjištění odlišitelnosti jednotlivých tříd. Při srovnání obou grafů vidíme, že mezi daty S-2 a PS není zásadní rozdíl (především v termínech, kdy je vegetace vyrostlá – 11. 5., 3. 6., 20. 6. a také v termínech po sklizni 28. 9., 29. 9. a 16. 10.). V termínech kdy je na plochách minimum vegetace, nebo je půda holá, tak hodnoty u PS jsou u některých tříd záporné (termíny 1. 4., 2 dva srpnové termíny a také 7. 12.), což by nemělo být, jelikož záporných hodnot nabývá NDVI, pokud se jedná o typy povrchů jako sníh, led, voda nebo i oblačnost. V každém případě toto svědčí o tom, že na polích v této době nebyla vegetace. Ze sloupcových hodnot můžeme vidět odlišitelnosti v jednotlivých termínech.

V termínu 1. 1. dosahují nejvyšších hodnot ozimé plodiny (ječmen ozimý a řepka ozimá), které jsou už v tomto období vyklíčené z podzimu a jsou ve stavu přezimování.

V termínu 1. 4. dosahují podobných hodnot třídy cukrovka, ječmen jarní, kukuřice a pšenice jarní (vše jařiny). Tím pádem jsou všechny od sebe špatně odlišitelné. Ozimé plodiny (ječmen ozimý, pšenice ozimá a řepka ozimá) dosahují mnohem vyšších hodnot z důvodu dřívějšího klíčení a růstu po zimním období. Navzájem se tyto plodiny v tomto období stále špatně odlišily (výjimkou byla dvojice ječmen ozimý a řepka ozimá). Dobré odlišitelnosti dosáhly vždy jedna plodina z jařin vůči jedné ozimé plodině a zároveň jařiny vůči trávám.

V termínu 11. 5. se výrazně zvýšila hodnota ječmene jarního, který má velmi rychlý nástup hlavní vegetační fáze. To samé platí i pro pšenici jarní. Cukrovka a kukuřice stále ještě nezačaly výrazně růst (nízké hodnoty NDVI). Kategorie trávy v tomto období dosahuje vegetačního vrcholu. Dobré odlišitelnosti dosáhly cukrovka nebo kukuřice od všech ozimých plodin, trav nebo od ječmene jarního. Špatná odlišitelnost je pak u ozimých plodin, trav a ječmene jarního mezi sebou.

V termínu 3. 6. postupně dochází k nástupu růstu cukrovky (zvýšení NDVI hodnoty). Kukuřice je stále ještě ve stavu, kdy malé množství biomasy odpovídá nízkému NDVI. Dobrá odlišitelnost byla pro třídu kukuřice vůči všem zbylým třídám a také pro třídu cukrovka vůči všem zbylým třídám. Špatně odlišitelné jsou pak třídy ječmen jarní a ozimý, pšenice jarní a ozimá a řepka ozimá. Relativně dobře bylo možné odlišit i trávy od kukuřice. Pokles NDVI hodnoty pro trávy byl způsoben kosením.

V termínu 20. 6. pokračuje cukrovka v růstu a postupně dosahuje svého vegetačního vrcholu. V tomto termínu je již patrná fáze růstu pro třídu kukuřice (zvýšení NDVI hodnoty). Ozimé plodiny řepka a pšenice ozimá a pšenice jarní si udržují podobné hodnoty jako v předchozím termínu. K poklesu hodnot došlo u ječmene, který postupně ustupuje z hlavní vegetační fáze, zraje a následně přechází do období, kdy následuje sklizeň. U travních porostů se hodnota NDVI zvýšila, jelikož po kosení opět došlo k růstu. Dobré odlišitelnosti dosáhla kukuřice vůči všem ostatním plodinám (nepatrně hůře vůči ječmenu ozimému). Špatná odlišitelnost byla navzájem u tříd cukrovka, ječmen jarní, pšenice jarní a ozimá, řepka ozimá, trávy.

Pokud porovnáme poměr sloupců jednotlivých tříd mezi S-2 a PS v tomto termínu, tak vidíme, že naprostou shodu což dokazuje, že rozdílná data správně zobrazují prostřednictvím indexu NDVI stav vegetace na zemském povrchu.


U následujícího termínu (7. 8.) je vidět výrazný pokles hodnot u tříd ječmen jarní a ozimý, pšenice jarní a ozimá a řepka ozimá, což dokazuje, že již před tímto termínem došlo ke sklizni

dané plodiny. Třídy cukrovka a kukuřice stále pokračují ve své v hlavní vegetační fázi. Trávy si drží srovnatelnou hodnotu s předchozím termínem. Dobrá odlišitelnost tedy byla u jedné třídy ze skupiny ječmen jarní a ozimý, pšenice jarní a ozimá a řepka ozimá vůči cukrovce, nebo kukuřici, nebo trávám.

Termín 29. 8. v podstatě vykazuje podobné hodnoty či poměry mezi třídami. K nepatrnému nárůstu došlo u třídy řepka ozimá, což bylo pravděpodobně zapříčiněno nárůstem přirozené vegetace na již sklizené ploše. Odlišitelnost u plodin je v tomto termínu stejná jako u předchozího termínu.

Termíny pozdější než 29. 8. jsem již nepopisoval, jelikož už obsahují i hodnoty jiných plodin, které jsou vysazovány na následující sezónu. Výjimkou je cukrovka, u které došlo ke sklizni ne dříve než 16. 10., jelikož i v tomto termínu dosahuje vysokých NDVI hodnot.

Graf 10: Porovnání NDVI hodnot pro data S-2 a PS v jednotlivých termínech




6.1.11. Spektrální hodnoty v pásmech S-2

Následující graf (viz Graf 11) potvrzuje informace, které jsem interpretoval z NDVI grafů v předchozí kapitole. Z křivek vidíme, že nejvýraznější rozdíly odlišitelnosti se projevují v pásmech 5 – RED EDGE 2, 6 – RED EDGE 3, 7 – NIR 1, 8 – NIR 2. Ve zbylých pásmech (především RGB) hodnoty spíše korelují. Nicméně toto tvrzení neplatí pro všechny plodiny, jelikož průběh křivek je pro každou plodinu specifický. Nejpodobnější průběh křivek mají třídy pšenice jarní a ječmen jarní (nejvíce se odlišují v termínu 11. 5. v pásmech 6, 7, 8. Nejvýraznější odlišitelnost se projevuje u tříd řepka ozimá vůči jedné třídě z dvojice cukrovka a kukuřice

(nejvýraznější rozdíl v termínu 11. 5.). Výjimkou je ale termín 20. 6. kdy cukrovka a kukuřice dosahují téměř stejných hodnot ve všech pásmech v tomto termínu. Celkově dobrou odlišitelnost také vykazují jedna třída ze skupiny pšenice ozimá, pšenice jarní, ječmen ozimý a ječmen jarní vůči skupině tříd cukrovka, trávy, kukuřice a řepka ozimá v termínech 7. a 29. 8.

Nejlepší odlišitelnost pro všechny třídy se jeví v termínu 3. 6. a 7. 8. (částečně i 20. 6.), jelikož jednotlivé křivky jsou od sebe nejvíce navzájem vzdáleny a tím pádem dosahují rozdílnějších hodnot. Termíny 3. 6. u dat PS a 20. 6. u dat S-2 také dosáhly nejvyšší separability trénovacích tříd, což se právě projevilo i na křivkách v grafu (viz Graf 11).

Graf 11: Spektrální hodnoty pásem jednotlivých tříd pro S-2



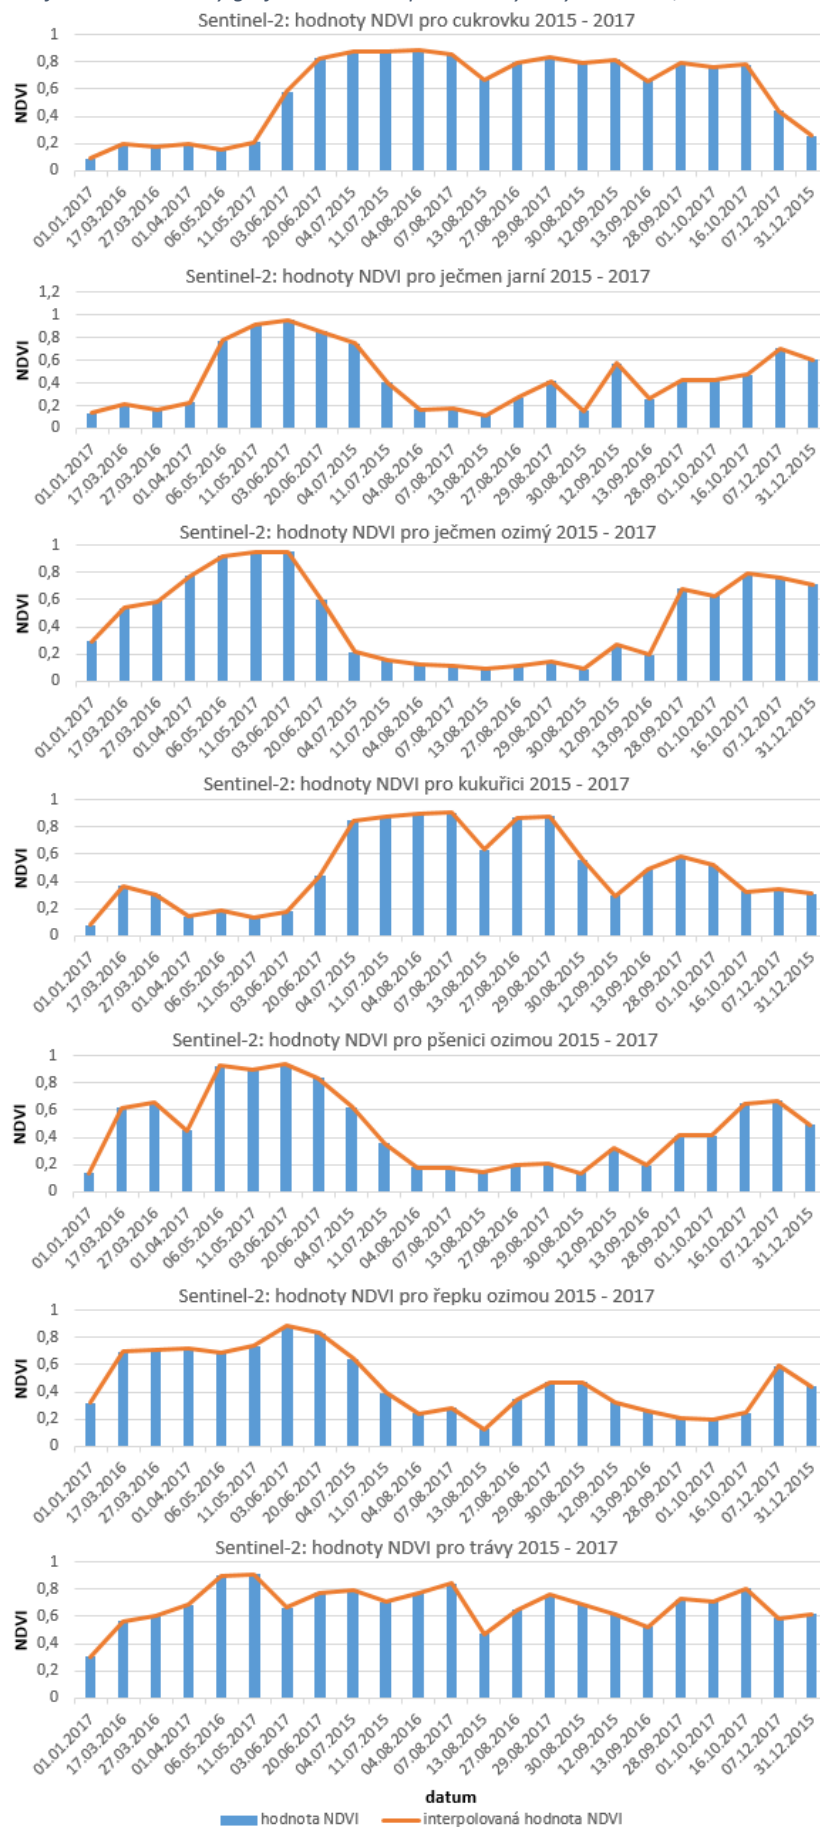
6.1.12. Kombinované spektrální grafy z let 2015 až 2017

Pro získání podrobnější časové řady spektrálních průběhů křivek jsem vytvořil kombinovaný graf hodnot, který reprezentuje DN a NDVI hodnoty (Graf 12 a Graf 13) z let 2015, 2016 a 2017 dohromady v jedné časové linii (pro stejné plodiny v průběhu těchto let pěstované na různých místech – zjištěno na základě dat SZIF pro tyto roky). Díky tomu vznikly mnohem kratší intervaly mezi jednotlivými termíny a spektrální průběh je podrobněji popsán. Je potřeba brát ale v úvahu, že ne každý rok jsou stejné podmínky (roční průběh počasí, odrůda plodiny, ...) a hodnoty ve stejných dnech ve třech zmiňovaných letech se mohou nepatrně lišit. Graf je vytvořen pouze pro data S-2, jelikož data PS jsou dostupná až od poloviny roku 2016. Pro třídu pšenice jarní nebyl kombinovaný graf vytvořen, jelikož v letech 2015 a 2016 se tato plodina nevyskytovala v datech, která mi byla poskytnuta.

Graf 12: Kombinovaný graf DN hodnot pro všechny třídy z let 2015, 2016 a 2017



Graf 13: Kombinovaný graf NDVI hodnot pro všechny třídy z let 2015, 2016 a 2017



Kombinované grafy (oproti méně podrobným grafům v předchozí kapitole) přinesly mnohem podrobnější spektrální průběh pro každou třídu. Především doplnily časovou „díru“ mezi 22. 6. 2017 a 7. 8. 2017, kdy dochází k výrazným změnám v rámci každé třídy z důvodu přechodu hlavního vegetačního období do období sklizně. Díky kombinovanému grafu jsem mnohem lépe dokázal popsat fenofáze pro jednotlivé třídy, respektive přesněji určil hranice mezi třetí a čtvrtou fenofází (viz následující kapitola).

6.2. Fenofáze jednotlivých tříd (plodin)

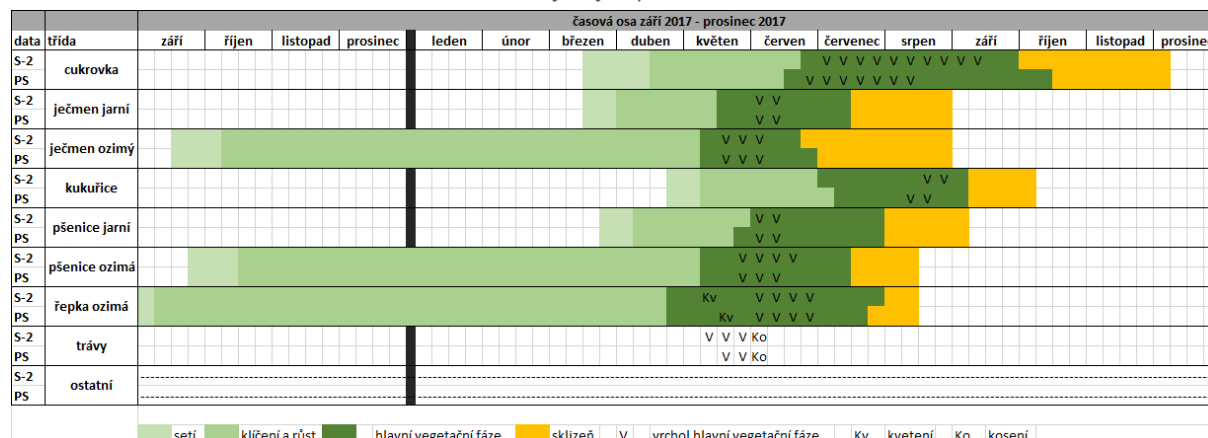
Výsledkem interpretace výše prezentovaných grafů jsou fenofáze (viz Tab. 12) jednotlivých tříd zvláště pro data S-2 a PS. Pro účely diplomové práce jsem pracoval se čtyřmi fenofázemi: 1) setí, 2) klíčení a růst, 3) hlavní vegetační fáze, v níž se objevuje vegetační vrchol, 4) sklizeň. Za vegetační vrchol považuji v souladu s literaturou (Pan et al., 2015) období (v mém případě konkrétní termín snímku), který je reprezentován nejvyšší hodnotou NDVI. Vegetační vrchol je jedním z období, u něhož se předpokládá možnost dobré odlišitelnosti jednotlivých plodin. Další fáze, kdy se plodiny můžou spektrálně dost odlišovat, je doba kvetení (u řepky ozimé) a kosení (platí u trav). To platí zejména pro plodiny s významným množstvím květů s jinou než zelenou barvou – v mém případě pro řepku ozimou (kvetení se zde projevuje poklesem hodnoty NDVI v termínu 18. 5. 2017 u dat PS a nepatrně v termínu 6. 5. 2016 u dat S-2). Řepka by v tomto termínu mohla být dobře odlišitelná od ostatních plodin.

U trav se dá předpokládat, že se jejich NDVI sníží v době kosení (tento projev je vidět ze všech grafů NDVI na počátku června, kdy došlo ke snížení hodnoty NDVI). Tím pádem by tento pokles mohl být vhodný k odlišení trav od obilovin a jiných plodin. Kvetení se také výrazně projevuje u třídy kukuřice (pokles NDVI hodnoty v termínu 10. 8. u dat PS a 13. 8. u kombinovaného grafu S-2). Znamky poklesů NDVI v předpokládané době kosení mohou pomoci odlišit trávy (počátek června) od obilovin (také zelené porosty jednoděložných plodin bez významných známek kvetení).

Z Tab. 12, která byla zpracována analýzou všech grafů (především grafy NDVI) pro jednotlivé plodiny vidíme jasný rozdíl mezi ozimými plodinami a jařinami, a to především v dřívějším nástupu hlavní vegetační fáze ozimých plodin a také v dřívější sklizni. Nejrychlejší nástup hlavní vegetační fáze (a dosažení vegetačního vrcholu) má ječmen ozimý, který má zároveň velmi krátké období produkce. Naopak nejpozději ze všech plodin vyklíčí a vyrostе kukuřice. Nejdelší fenofázi hlavní vegetační fáze má cukrovka. Toto období trvá přibližně tři měsíce (od června do konce září). Dobré odlišitelnosti by dosáhla kukuřice od ječmene

ozimého a od pšenice jarní, jelikož jejich vrcholy hlavní vegetační fáze se míjejí. Naopak nejhůře odlišitelné na základě fenofází vycházejí dvojice plodin řepka ozimá, pšenice ozimá, jelikož mají velmi podobný průběh fenofází (především vegetační vrchol), nicméně odlišitelný termín pro tyto dvě plodiny, by mohla být květen, kdy dojde k poklesu NDVI u řepky ozimé vlivem kvetení.

Tab. 12: Porovnání fenofází pro data S-2 a PS



U třídy trávy jsem vyznačil vrchol vegetační fáze, jelikož si po celý rok udržuje velmi podobné spektrální hodnoty (výjimkou je doba kosení, kdy došlo k úbytku biomasy – v grafu Ko – na počátku června, kde by trávy mohly být odlišitelné od jiných plodin) a jako jediná ze všech tříd nemá období setí a růstu a také sklizně, nýbrž z velké části podléhá přirozeným jevům v rámci chování přírody.

Třidu ostatní jsem do fenofází nezahrnoval, jelikož je tvořena různými zbylými plodinami a neměla by tak signifikantní spektrální projevy, ale pouze jejich „směsici“.

Při porovnání projevů fenofází (Tab. 12) pro každou třídu mezi daty S-2 (vždy první řádek u plodiny) a PS (druhý řádek) vidíme, že jednotlivé fáze jsou si velmi podobné. Malé rozdíly v případě některých plodin můžou být dány nastavením hranic intervalů mezi fenofázemi pro oba typy dat (viz výše), případně rozdíly v zastoupení pásem důležitých pro detekci vegetace v obou typech dat.

V rámci srovnání s obecnými tabulkovými termíny pro setí a sklizeň jednotlivých plodin z kapitoly 5.1.3. se období sklizně výrazně liší u plodin: ječmen jarní (sklizeň z mých interpretací o čtrnáct dní dříve) a pšenice ozimá (sklizeň o dva až tři týdny dříve, a to v polovině července). Dalo by se to vysvětlit tím, že v roce 2017 bylo teplé léto a plodiny uzrály a byly sklizeny dříve. Ze statistik Českého hydrometeorologického ústavu (ČHMÚ, 2018) vyplývá, že

průměrná květnová a červnová teplota pro Středočeský a Pardubický kraj v roce 2017 byla o cca dva stupně Celsia vyšší než v letech 2016, 2015 a 2014.

Termíny sklizně u zbylých plodin s obecnými termíny korelují. Co se týče termínu setí, tak ten z vytvořených grafů nelze přesně identifikovat, a tak jsem ho převzal pouze z obecných termínů pro jednotlivé plodiny.

6.3. Výsledky klasifikací

V práci byly testovány dvě metody pixelové a dvě metody objektové klasifikace. V této kapitole je zhodnocena a porovnána jejich přesnost.

U každé třídy v rámci klasifikačních výsledků je srovnána přesnost ZP – zpracovatelská přesnost a UP – uživatelská přesnost. Dále je srovnávána celková přesnost klasifikací navzájem. Vyšší přesnost je vždy zvýrazněna barvou (ZP – světle červenou barvou a UP – světle modrou barvou). Světle červenou barvou jsou zvýrazněny i vyšší celkové přesnosti.

6.3.1. Celkové přesnosti pixelové klasifikace

Z pixelových klasifikátorů byly využity přístupy *Maximum likelihood* a SVM. Lepších výsledků dosáhly podle očekávání multitemporální datasety. Přitom mírně lepších výsledků bylo dosaženo metodou ML. Celková přesnost nejlepší pixelové klasifikace metodou ML byla 88,4 % a Kappa koeficient 0,8518 (tyto hodnoty byly dosaženy pro 1. multitemporální dataset) a metodou SVM 83,59 %, Kappa koeficient 0,795 (viz Tab. 24 v seznamu příloh – přehled všech klasifikací dle celkové přesnosti).

Tab. 13: Nejlepší výsledky pixelové klasifikace pro každý dataset

dataset	celková přesnost (%)
1. multitemporální dataset S-2	88,40
2. multitemporální dataset S-2	86,30
multitemporální dataset PS	84,85
NDVI dataset S-2	70,53
NDVI dataset PS	65,01
PCA dataset S-2	68,81
PCA dataset PS	62,68

V Tab. 13 uvádím nejvyšší celkové přesnosti pro každý dataset zvlášť (vše bylo dosaženo klasifikátorem ML). Nejvyšší celkové přesnosti bylo dosaženo pro 1. multitemporální dataset S-2, který disponoval pásmy RED EDGE a SWIR. Přesnost klasifikace s využitím těchto pásem byla oproti 2. multitemporálnímu datasetu S-2 (pouze pásma RGB a NIR) cca 2 % vyšší. Ze všech multitemporálních datasetů dosáhl nejnižší přesnosti dataset PS. Ve srovnání

s 2. multitemporálním datasetem S-2, který disponuje stejnými pásmy, avšak s menším prostorovým rozlišením, byla přesnost pro PS o cca 1,5 % nižší. Výrazně nižší přesnosti dosáhly datasety NDVI a také PCA datasety (viz Tab. 24 v seznamu příloh – přehled všech klasifikací dle celkové přesnosti). U S-2 byla aplikována metoda PCA na 1. multitemporální dataset S-2, který disponoval šedesáti pásmy.

6.3.1.1. Vyhodnocení přesnosti multitemporální přístupu pro jednotlivé třídy

Tab. 14: Porovnání pixelové klasifikace 1. a 2. multitemporálního datasetu S-2

1. multitemporální dataset Sentinel-2					2. multitemporální dataset Sentinel-2			
CP = (541799/612864) 88.4044%					CP = (528904/612858) 86.3012%			
Kappa koeficient = 0.8518					Kappa koeficient = 0.8269			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	90,13	98,31	1,69	9,87	81,19	98,26	1,74	18,81
ječmen jarní	71,93	98,46	1,54	28,07	69,56	96,17	3,83	30,44
ječmen ozimý	85,88	92,77	7,23	14,12	87,77	87,96	12,04	12,23
kukuřice	86,83	99,93	0,07	13,17	86,47	99,56	0,44	13,53
ostatní	67,84	50,34	49,66	32,16	69,34	43,46	56,54	30,66
pšenice jarní	27,35	35,53	64,47	72,65	43,76	29,69	70,31	56,24
pšenice ozimá	93,54	92,16	7,84	6,46	90,39	95,51	4,49	9,61
řepka ozimá	97,27	98,86	1,14	2,73	96,24	99,37	0,63	3,76
trávy	95,02	83,83	16,17	4,98	88,43	78,86	21,14	11,57

V rámci hodnocení přesnosti klasifikace jednotlivých plodin byly porovnány nejprve 1. a 2. multitemporální dataset S-2 (viz Tab. 14). Výhodu pásem v 1. multitemporálním datasetu S-2 jsem již zmiňoval v předchozí kapitole. Z tabulky vidíme, že pro jednotlivé třídy dosáhl v průměru lepší zpracovatelské (ZP) a uživatelské (UP) přesnosti 1. multitemporální dataset S-2. Avšak u některých tříd bylo dosaženo nepatrně vyšší ZP (u tříd kukuřice o 0,3 %, ostatní 1,5 %, pšenice jarní 16 %) a UP (u tříd pšenice ozimá o 3,5 %, řepka ozimá o 0,5 %) u 2. multitemporálního datasetu S-2. Nejvýraznější rozdíl v ZP (cca 16 %) a UP (cca 6 %) je u třídy pšenice jarní, která dosáhla nejnižší přesnosti ze všech tříd. Nejvyšší přesnosti (ZP i UP) dosáhla třída řepka ozimá. Nejvyšší chybovosti dosáhly třídy ostatní a především pšenice jarní (z chybových matic jsem zjistil, že u ZP došlo nejčastěji k záměně za třídy ostatní a pšenice ozimá a UP za třídy ječmen jarní a pšenice ozimá). Je potřeba brát v úvahu, že kategorie ostatní je směsice několika druhů plodin a tím pádem budou výsledky přesností poměrně zkreslené ve srovnání s ostatními třídami. Naopak nejvyšší přesnosti bylo dosaženo z hlediska ZP pro třídy řepka ozimá a trávy a v rámci UP pro třídy kukuřice a řepka ozimá.

V Tab. 15 je srovnání nejlepšího výsledku pixelové klasifikace pro data S-2 a pro data PS. Lepší celkové přesnosti tedy dosáhl S-2. Nejhuře klasifikované třídy byly i v případě PS pšenice jarní a třída ostatní. Největší rozdíl ZP mezi oběma typy dat byl u třídy cukrovka (S-2: 90,13 %, PS: 76,17 %) a pro UP u třídy ječmen ozimý (S-2: 92,77 %, PS: 60,74 %).

Tab. 15: Porovnání přesnosti pixelové klasifikace 1. multitemporálního datasetu S-2 a multitemporálního datasetu PS

1. multitemporální dataset Sentinel-2					multitemporální dataset PlanetScope			
CP = (541799/612864) 88.4044%					CP = (4554183/5367054) 84.8544%			
Kappa koeficient = 0.8518					Kappa Coefficient = 0.8108			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	90,13	98,31	1,69	9,87	76,17	98,02	1,98	23,83
ječmen jarní	71,93	98,46	1,54	28,07	66,50	90,50	9,50	33,50
ječmen ozimý	85,88	92,77	7,23	14,12	97,84	60,74	39,26	2,16
kukuřice	86,83	99,93	0,07	13,17	92,66	98,14	1,86	7,34
ostatní	67,84	50,34	49,66	32,16	79,32	48,85	51,15	20,68
pšenice jarní	27,35	35,53	64,47	72,65	28,34	14,64	85,36	71,66
pšenice ozimá	93,54	92,16	7,84	6,46	85,98	95,28	4,72	14,02
řepka ozimá	97,27	98,86	1,14	2,73	94,80	99,32	0,68	5,20
trávy	95,02	83,83	16,17	4,98	84,17	85,49	14,51	15,83

Dále bylo také do seznamu příloh vloženo porovnání (viz Tab. 27 v přílohách) mezi 2. multitemporálním datasetem S-2 a multitemporálním datasetem PS z důvodu, že oba datasety měly stejná spektrální pásma RGB a NIR. Výsledky vycházejí velmi podobně (opět ve prospěch 2. multitemporálního datasetu S-2) ve srovnání s Tab. 15.

6.3.1.2. Vyhodnocení přesnosti monotemporálního přístupu pro jednotlivé třídy

V rámci monotemporálního přístupu bylo dosaženou nejvyšší celkové přesnosti v termínu 20. 6. 2017 (76,2 % u dat S-2) a 3. 6. 2017 (67,13 % u dat PS) (viz Tab. 28 v přílohách), což znamená, že pokud bychom chtěli využít monotemporální přístup a dosáhnout nejvyšší přesnosti klasifikace v průběhu roku, tak bychom měli využít červnové termíny (viz Tab. 25 v přílohách). U obou typů dat platí, že nejhorších přesností bylo dosaženo ke konci srpna. U dubnových či květnových termínů byla přesnost vyšší (v průměru o 10 %) ve srovnání se srpnovými termíny.

Z Tab. 16 také vidíme, že S-2 dosahuje opět vyšších přesností pro každou třídu. Nepatrnou výjimkou je kukuřice a pšenice ozimá (vyšší ZP u PS) a třída ostatní s vyšší UP též u PS. Z červnových termínů, kdy bylo dosaženo nejvyšších přesností, můžeme vidět také souvislost s Tab. 9, která popisuje odlišitelnost ROI v jednotlivých termínech. Právě červnové termíny vykazovaly nejlepší průměrnou hodnotu separability, což se projevilo i vyššími celkovými přesnostmi.

Tab. 16: Srovnání přesnosti klasifikace dvou nejlepších monotemporálních pixelových klasifikací pro S-2 a PS

Sentinel-2					PlanetScope			
CP = (466922/612858) 76.1876%					CP = (3603048/5367054) 67.1327%			
Kappa koeficient = 0,7103					Kappa Coefficient = 0,5980			
(20.6.2017)					(3.6.2017)			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	79,34	95,87	4,13	20,66	74,96	49,67	50,33	25,04
ječmen jarní	71,58	67,60	32,40	28,42	53,50	36,63	63,37	46,50
ječmen ozimý	95,37	47,17	52,83	4,63	40,32	11,18	88,82	59,68
kukuřice	85,64	95,09	4,91	14,36	86,83	92,42	7,58	13,17
ostatní	53,74	40,42	59,58	46,26	23,89	41,84	58,16	76,11
pšenice jarní	38,90	8,06	91,94	61,10	14,21	5,60	94,40	85,79
pšenice ozimá	68,80	94,01	5,99	31,20	72,04	90,62	9,38	27,96
řepka ozimá	92,95	99,38	0,62	7,05	87,95	88,32	11,68	12,05
trávy	89,57	74,69	25,31	10,43	41,10	46,81	53,19	58,90

Z výsledků monotemporálních klasifikací dále vyplývá, že ozimé plodiny dosáhly vyšších přesností v termínech do konce června a jařiny (především kukuřice) naopak (termíny pozdější než červen).

6.3.2. Objektová klasifikace

V rámci objektové klasifikace byly testovány klasifikační metody KNN (*K-nearest Neighbours*), PCA (*Principal Component Analysis*) a SVM (*Support Vector Machine*). Nejlépe dopadla metoda SVM (viz Tab. 24 v seznamu příloh – přehled všech klasifikací dle celkové přesnosti). Bylo dosaženo velmi podobných výsledků, co se týče celkové přesnosti datasetů v Tab. 17.

Tab. 17: Nejlepší výsledky objektové klasifikace pro každý dataset

dataset	celková přesnost (%)
1. multitemporální dataset S-2	86,98
2. multitemporální dataset S-2	87,29
multitemporální dataset PS	85,30

Z Tab. 17 vidíme, že nejvyšší celkové přesnosti dosáhl 2. multitemporální dataset S-2 bez využití pásem RED EDGE a SWIR (rozdíl oproti 1. multitemporálního datasetu byl 0,3 %). Detailnější porovnání objektové klasifikace obou multitemporálních datasetů S-2 je v seznamu příloh (viz Tab. 26 v přílohách). Lepší přesnosti pro jednotlivé plodiny dosáhla klasifikace nad 1. multitemporálním datasetem. Celkové přesnosti všech metod objektové klasifikace k tomuto datasetu jsou uvedeny v Tab. 26 v přílohách.

V další tabulce (Tab. 18) jsou detailněji porovnány nejlepší výsledky objektové klasifikace pro S-2 a PS. Mírně lepší přesnosti dosáhla opět objektová klasifikace z dat S-2 (cca o 2 % vyšší celková přesnost). Nejnižších přesností, jak ZP, tak UP dosáhly opět třídy pšenice jarní a ostatní. Kromě ječmene ozimého a jeho UP dosáhly všechny třídy vysoké přesnosti a to nad 80 %, většina tříd pak i přes 90 %. V Tab. 18 také vidíme porovnání celkových přesností objektové klasifikace na obou datasetech. Téměř všechny klasifikační metody (kromě metody PCA) vyšly lépe pro data S-2. Stejně jako u pixelové klasifikace dosáhla metoda PCA nejnižší celkové přesnosti. Ukazuje se, že pro multitemporální datasety v rámci klasifikace mnou definovaných tříd není tato metoda vhodná.

Tab. 18: Porovnání přesností objektové klasifikace 2. multitemporálního datasetu S-2 a multitemporálního datasetu PS

2. multitemporální dataset Sentinel-2					multitemporální dataset PlanetScope			
CP = (483327/553679) 87,2937%					CP = (4526371/5306793) 85,2939%			
Kappa koeficient = 0,8383					Kappa koeficient = 0,8143			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	95,97	82,68	17,32	4,03	84,25	95,32	4,68	15,75
ječmen jarní	80,39	89,86	10,14	19,61	77,56	87,56	12,44	22,44
ječmen ozimý	96,23	56,73	43,27	3,77	98,65	58,04	41,96	1,35
kukuřice	83,65	95,81	4,19	16,35	90,88	96,25	3,75	9,12
ostatní	52,69	66,49	33,51	47,31	51,23	60,47	39,53	48,77
pšenice jarní	33,28	14,80	85,20	66,72	23,55	11,55	88,45	76,45
pšenice ozimá	92,38	96,27	3,73	7,62	88,43	89,80	10,20	11,57
řepka ozimá	96,60	94,93	5,07	3,40	90,87	85,24	14,76	9,13
trávy	95,06	81,19	18,81	4,94	98,45	96,47	3,53	1,55
klasifikační metoda		2. md. Sentinel-2		md. PlanetScope				
		celková přesnost (%)						
KNN		79,18		74,15				
PCA		12,34		43,88				
SVM linear		86,65		83,07				
SVM polynomial		85,67		85,30				
SVM sigmoid		79,15		75,38				
SVM radial basis		87,29		84,76				

6.3.3. Porovnání pixelové a objektové klasifikace

Tab. 19: Nejvyšší celkové přesnosti pixelové a objektové klasifikace pro všechny multitemporální datasety

	pixelová klasifikace	objektová klasifikace
dataset	celková přesnost (%)	
1. multitemporální dataset S-2	88,40	86,98
2. multitemporální dataset S-2	86,30	87,29
multitemporální dataset PS	84,85	85,30

Nejvyšší celkové přesnosti bylo dosaženo s využitím pixelové klasifikace 1. multitemporálního datasetu (88,4 %). Objektová klasifikace byla nejpřesnější v případě

2. multitemporálním datasetu S-2 (87, 3 %). Klasifikace na multitemporálním datasetu PS dosáhla nejnižší přesnosti (viz Tab. 19). Z výsledků vyplývá, že pásma RED EDGE a SWIR v rámci pixelové klasifikace mírně zvýšila přesnost. Na druhou stranu pro objektovou klasifikaci toto prokázáno nebylo, jelikož došlo k nepatrnému snížení přesnosti (cca o 0,3 % oproti 2. multitemporálnímu datasetu).

Tab. 20: Porovnání nejlepších výsledků pixelové a objektové klasifikace

1. multitemporální dataset Sentinel-2					2. multitemporální dataset Sentinel-2			
pixelová klasifikace					objektová klasifikace			
CP = (541799/612864) 88.4044%					CP = (483327/553679) 87,2937%			
Kappa koeficient = 0.8518					Kappa koeficient = 0,8383			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	90,13	98,31	1,69	9,87	95,97	82,68	4,03	17,32
ječmen jarní	71,93	98,46	1,54	28,07	80,39	89,86	19,61	10,14
ječmen ozimý	85,88	92,77	7,23	14,12	96,23	56,73	3,77	43,27
kukuřice	86,83	99,93	0,07	13,17	83,65	95,81	16,35	4,19
ostatní	67,84	50,34	49,66	32,16	52,69	66,49	47,31	33,51
pšenice jarní	27,35	35,53	64,47	72,65	33,28	14,80	66,72	85,20
pšenice ozimá	93,54	92,16	7,84	6,46	92,38	96,27	7,62	3,73
řepka ozimá	97,27	98,86	1,14	2,73	96,60	94,93	3,40	5,07
trávy	95,02	83,83	16,17	4,98	95,06	81,19	4,94	18,81

V další tabulce (viz Tab. 20) je zobrazeno porovnání nejlepšího výsledku pixelové a objektové klasifikace pro jednotlivé třídy. V případě obou typů klasifikací dosáhly nejlepších výsledků datasety S-2. V rámci ZP se lepší výsledky jeví pro pixelovou klasifikaci u tříd kukuřice (86,83 %), ostatní (67,84 %), pšenice ozimá (93,54 %) a řepka ozimá (97,27 %). U zbylých tříd (cukrovka, ječmen jarní, ječmen ozimý, pšenice jarní, trávy) byly dosaženo vyšší ZP u objektové klasifikace. Jinak je tomu u UP, která celkově lépe vyšla v pixelové klasifikaci (cukrovka 98,31 %, ječmen jarní 98,46 %, ječmen ozimý 92,77 %, kukuřice 99,93 %, pšenice jarní 35,53 %, řepka ozimá 98,86 %). U tříd ostatní a pšenice ozimá vyšla lépe UP u objektové klasifikace.

Nejhorších přesností opět dosáhly třídy pšenice jarní (ZP 27,35 % vs. 33,28 % a UP 35,53 % vs. 14,8 %) a ostatní (ZP 67,84 % vs. 52,67 % a UP 50,34 % vs. 66,49 %). Ostatní třídy ale dosáhly vždy vyšší ZP a UP než 80 % (výjimkou je třída ječmen jarní u S-2, kde ZP činila 71,93 %).

6.4. Výsledky klasifikací vs. skutečný stav z LPIS

V rámci validace výsledků jsem také provedl porovnání rozlohy vyklasifikovaných tříd (Tab. 21 a Graf 14) vůči rozlohám tříd v databázi LPIS v modelovém území (srovnány byly

pouze plochy vyklasifikované plochy, které měly překryv vůči plochám v databázi LPIS, u kterých byla jistota výskytu pouze jedné plodiny). Byly porovnány výsledky všech multitemporálních datasetů a jejich pixelové či objektové klasifikace. Dále jsem ze všech procentuálních rozloh pro každou třídu spočítal průměr a ten též porovnal se skutečným stavem.

Tab. 21: Porovnání rozlohy tříd získaných z jednotlivých klasifikací vůči rozlohám v LPIS (v %)

kategorie	LPIS pro S-2	S-2 PIX 1. md	S-2 PIX 2. md	S-2 OBJ 1. md	S-2 OBJ 2. md	průměr ze S-2	LPIS pro PS	PS PIX md	PS OBJ md	průměr z PS
	rozloha ploch v %						rozloha ploch v %			
cukrovka	5,20	4,39	4,70	5,49	6,14	5,18	5,68	4,66	5,53	5,10
ječmen jarní	8,01	6,36	6,34	7,30	7,84	6,96	8,07	6,46	7,56	7,01
ječmen ozimý	3,37	3,13	2,96	4,32	4,21	3,66	3,69	3,92	4,24	4,08
kukuřice	12,86	11,02	11,04	13,00	12,09	11,79	13,16	12,00	12,93	12,47
ostatní	9,25	15,84	13,75	8,40	8,05	11,51	9,46	17,57	8,64	13,11
pšenice jarní	2,91	3,21	2,21	6,42	4,48	4,08	2,85	4,01	4,52	4,27
pšenice ozimá	32,92	30,85	32,98	31,39	32,58	31,95	32,68	27,60	31,92	29,76
řepka ozimá	16,69	15,83	16,22	17,27	17,56	16,72	15,11	14,24	14,77	14,51
trávy	8,80	9,40	9,82	6,41	7,06	8,17	9,31	9,51	8,89	9,20

md multitemporální dataset, PIX pixelová klasifikace, OBJ objektová klasifikace

V Tab. 21 vidíme rozlohy tříd v procentech v testovaném území z databáze LPIS (červená čísla). Červeně vyznačená pole pak reprezentují hodnotu, která se nejvíce přiblížila skutečnému stavu. Pro data S-2 vidíme, že rozložení v červených polích je „rozeseto“ do všech klasifikací, nicméně rozlohy v procentech se u jednotlivých tříd příliš neliší od skutečného stavu. Výjimkou je třída ostatní, která u všech pixelových klasifikací cca dvojnásobně přesáhla skutečný stav. U objektové klasifikace ale vyšly pro tuto třídu rozlohy velmi dobře.

Nejvyšší přesnosti pixelové klasifikace dosáhla klasifikace na 1. multitemporální datasetu S-2 metodou ML (sloupec S-2 PIX 1. md) u objektové klasifikace to byl 2. multitemporální dataset S-2 (sloupce S-2 OBJ 2. md). Rozlohy u těchto dvou sloupců by měly být přesnější než u ostatních klasifikací. Nicméně porovnána byla jen množina dat, u které byl překryv s plochami z databáze LPIS, ale celkové přesnosti klasifikací byly vztaženy na celou plochu testovaného území.


U dat S-2 se lépe jeví pixelová klasifikace pro třídy ječmen ozimý, pšenice jarní, pšenice ozimá, řepka ozimá a trávy. Rozlohy tříd cukrovka, ječmen jarní, kukuřice a ostatní vyšly lépe v rámci objektové klasifikace.

U dat PS jednoznačně lépe vyšla objektová klasifikace. Šest z devíti tříd mělo přesnější procentuální rozlohu. Patří mezi ně cukrovka, ječmen jarní, kukuřice, ostatní, pšenice ozimá a řepka ozimá. Pro třídy ječmen ozimý, pšenice jarní a trávy vyšla lépe pixelová klasifikace. Stejně jako u pixelových klasifikací S-2 se projevuje i třída ostatní u pixelových klasifikací PS. Dokonce více než dvojnásobně překračuje skutečnou rozlohu (17,57 % vs. 9,46 %).

Společně pro oba typy dat vyšly procentuální rozlohy v rámci objektové klasifikace pro třídy cukrovka, ječmen jarní, kukuřice, ostatní a v rámci pixelové klasifikace třídy ječmen ozimý, pšenice jarní a trávy. Zbylé třídy pšenice jarní a řepka ozimá vyšly lépe pro pixelovou klasifikaci z dat S-2 a objektovou klasifikaci PS.

Lépe jsou všechny výsledky vidět v příložených grafech (viz Graf 14). Nejvýraznější rozdíly vidíme u třídy ostatní v rámci pixelové klasifikace. Oranžový sloupec reprezentuje průměrnou hodnotu všech procentuálních rozloh zvlášť pro klasifikace ze S-2 a PS. Vidíme, že průměrná hodnota se velmi blíží skutečnému stavu, což dokazuje dobré výsledky klasifikace. Výjimkou je samozřejmě již zmiňovaná třídy ostatní. Druhou nejméně přesnou třídou jsou trávy. Naopak nejlépe se skutečnému stavu přiblížila třída pšenice ozimá u klasifikací S-2 a kukuřice u klasifikací PS.

Graf 14: Porovnání rozlohy v procentech pro jednotlivé klasifikace vůči rozlohám v LPIS



6.5. Mapové výstupy

Hlavním výstupem klasifikace plodin jsou mapy (viz Mapová příloha č. 1, 2, 3 a 4) Mapové výstupy jsou čtyři a reprezentují jednak nejlepší výsledek klasifikace dat S-2 (pixelová klasifikace), dále nejlepší výsledek klasifikace dat PS (pixelová klasifikace) a také nejlepší

výsledek objektové klasifikace (byl dosažen pro data S-2). Dále jsem vytvořil také mapu rozmístění plodin z databáze LPIS pro porovnání s výstupy klasifikací. Ke každé mapě je přiložena i tabulka rozloh tříd v kilometrech čtverečních a procentech. Při srovnání map zobrazujících klasifikace působí lepším dojmem výsledek objektové klasifikace, jelikož plochy byly klasifikovány jako celek, na rozdíl od pixelové klasifikace, kde se projevuje efekt „sůl a pepř“, jednotlivé plochy vznikly spojením klasifikovaných pixelů a tím pádem jsou více heterogenní. Na výslednou klasifikaci nebyl použit filtr, aby spočítané rozlohy byly přesné.

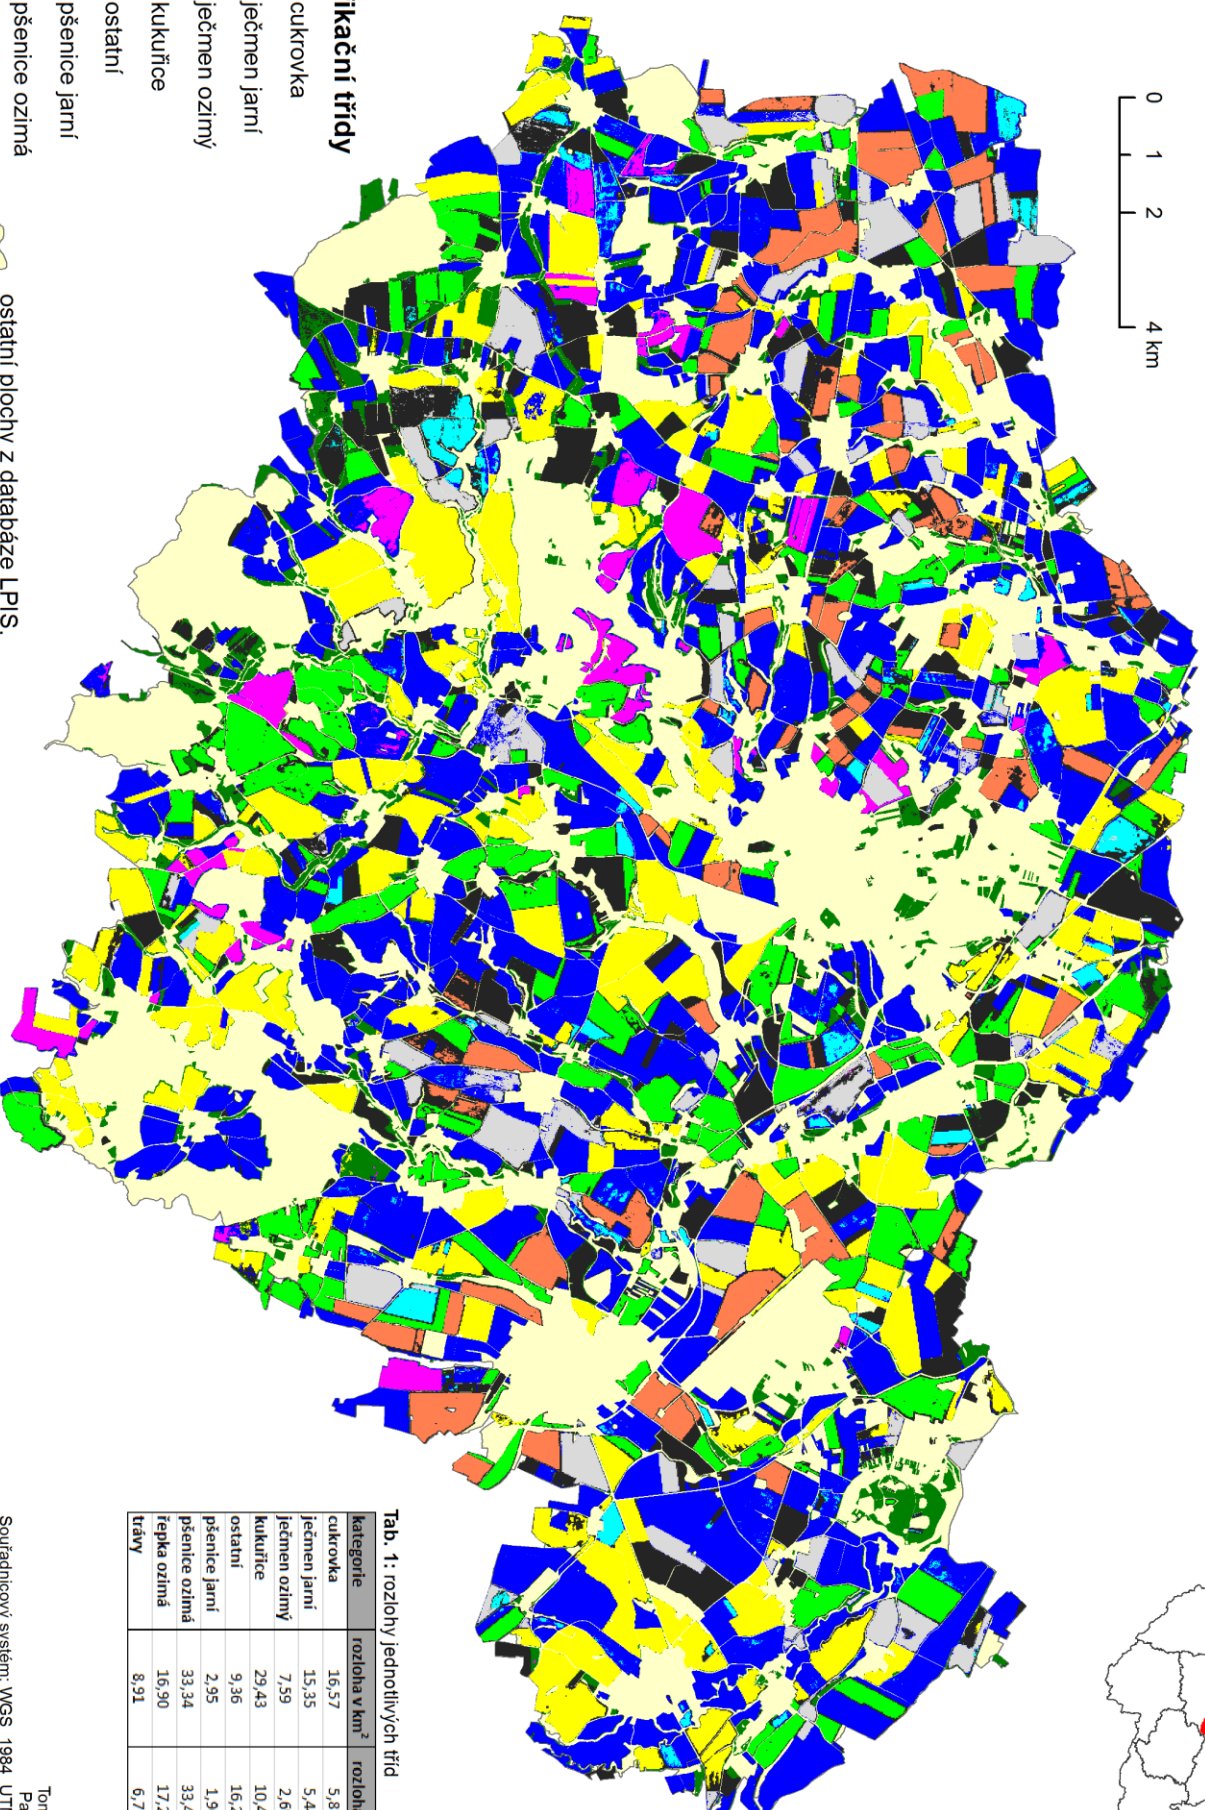

V rámci porovnání rozloh tříd u nejlepších klasifikací (viz tabulky u mapových výstupů nejlepší pixelové a objektové klasifikace z dat S-2) vidíme, že nejvýrazněji se v rozlohách liší třídy ječmen jarní (pixelová klasifikace – 5,44 %, objektová klasifikace – 8,15 %), ostatní (16,24 % vs. 8,44 %) a pšenice jarní (1,9 % vs. 3,86 %).

Při porovnání map (nejlepší pixelová klasifikace u S-2 a pixelová klasifikace u PS) je vidět zásadní rozdíl v tom, že část vyklasifikovaných ploch u pixelové klasifikace PS chybí. Tento důvod jsem již popisoval v kapitole 4.2. Co se týče porovnání rozloh vyklasifikovaných tříd, tak největší rozdíly se vyskytly u tříd ječmen ozimý (pixelová klasifikace S-2 – 2,69 %, pixelová klasifikace PS 4,45 %), pšenice jarní (1,9 % vs. 3,68 %) a pšenice ozimá (33,43 % vs. 27,97 %).

Detailní porovnání rozloh vyklasifikovaných tříd ve srovnání s databází LPIS bylo popsáno v předešlé kapitole 6.4.

PIXELOVÁ KLASIFIKACE S NEJVYŠŠÍ PŘESNOSTÍ

1. multitemporální dataset S-2, metoda ML, rok 2017



Klasifikační třídy

- cukrovka
- ječmen jarní
- ječmen ozimý
- kukuřice
- ostatní
- pšenice jarní
- pšenice ozimá
- řepka ozimá
- travy

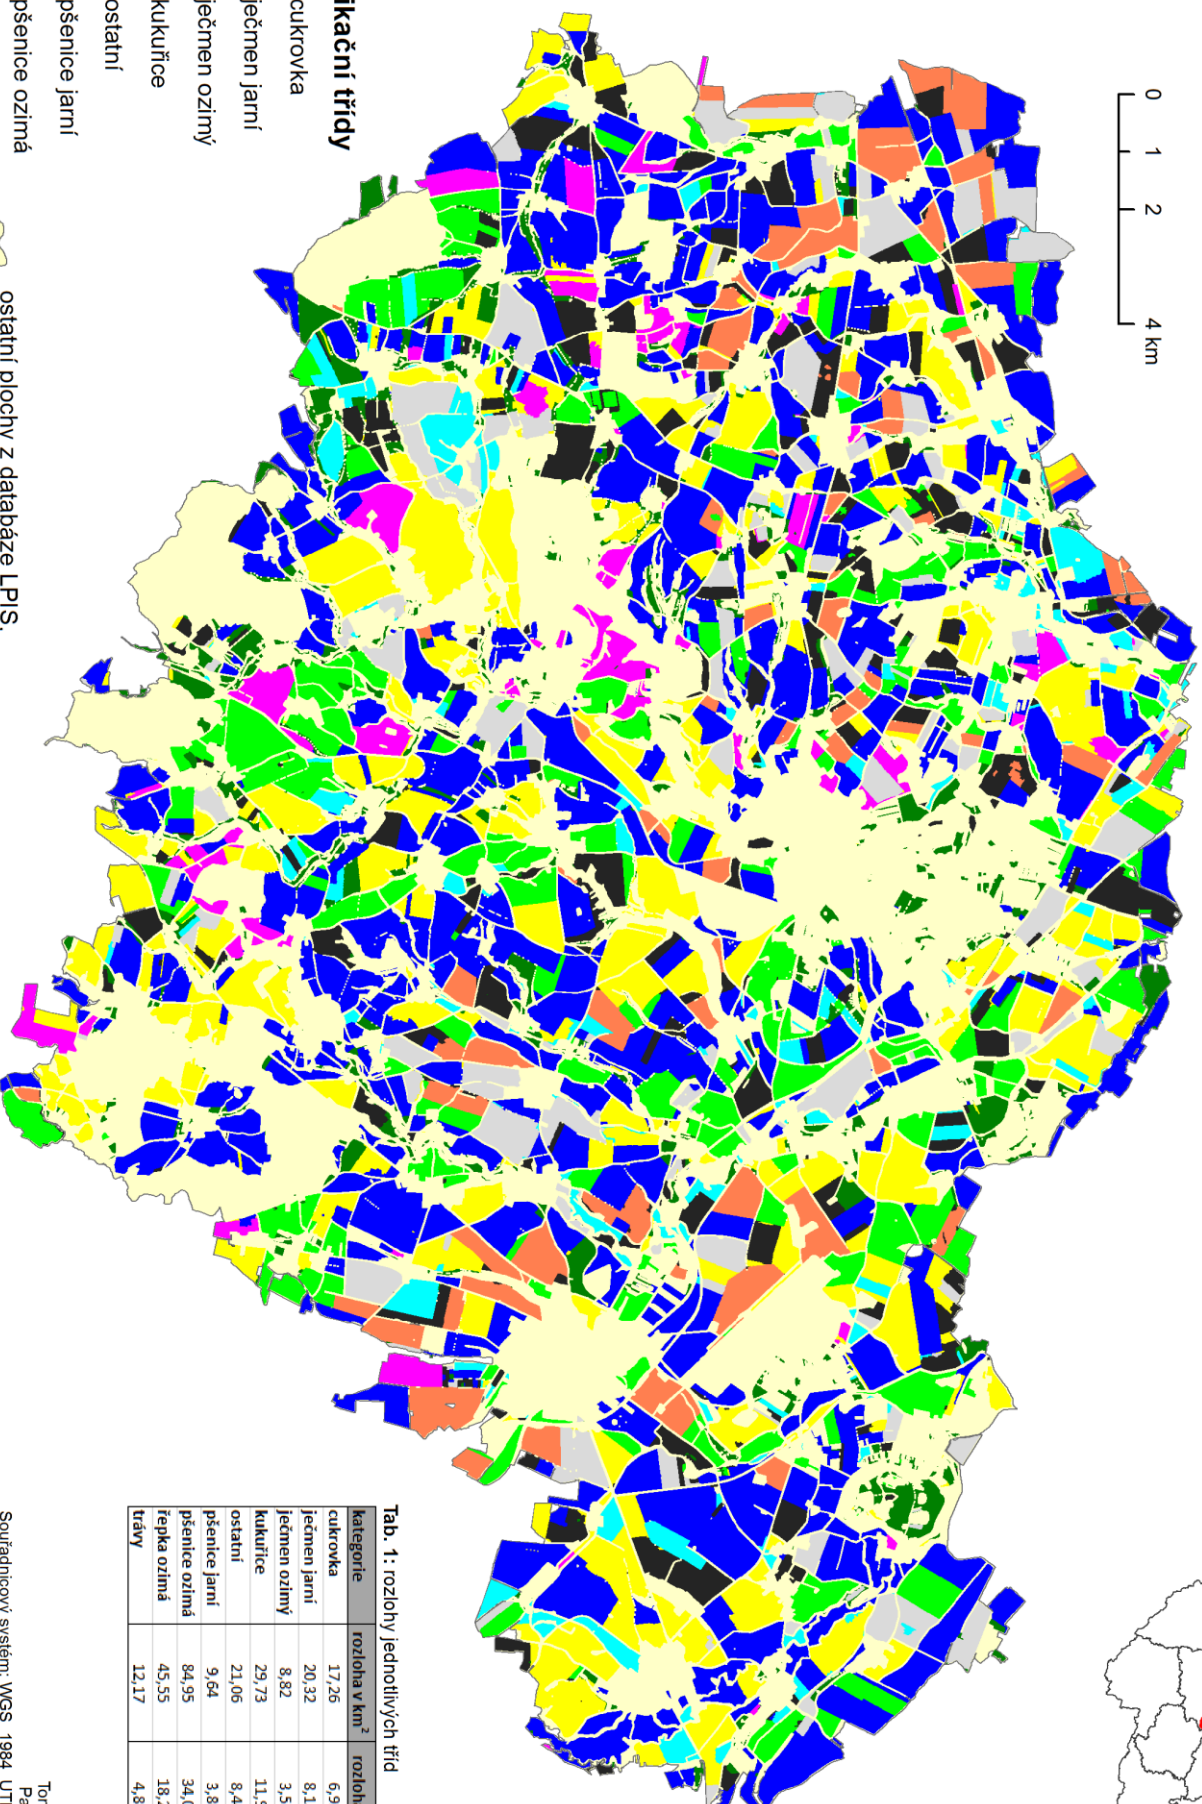

- ostatní plochy z databáze LPIs,
- les, zástavba, vodní plocha
- hranice území

Tab. 1: rozlohy jednotlivých tříd

kategorie	rozloha v km ²	rozloha v %
cukrovka	16,57	5,87
ječmen jarní	15,35	5,44
ječmen ozimý	7,59	2,69
kukuřice	29,43	10,43
ostatní	9,36	16,24
pšenice jarní	2,95	1,90
pšenice ozimá	33,34	33,43
řepka ozimá	16,90	17,29
travy	8,91	6,71

OBJEKTOVÁ KLASIFIKACE S NEJVYŠŠÍ PŘESNOSTÍ

2. multitemporální dataset S-2, metoda SVM - radial basis, 2017



Klasifikační třídy

- cukrovka
- ječmen jarní
- ječmen ozimý
- kukuřice
- ostatní
- pšenice jarní
- pšenice ozimá
- řepka ozimá
- tráv

- ostatní plochy z databáze LPIs,
- les, zástavba, vodní plocha
- hranice území

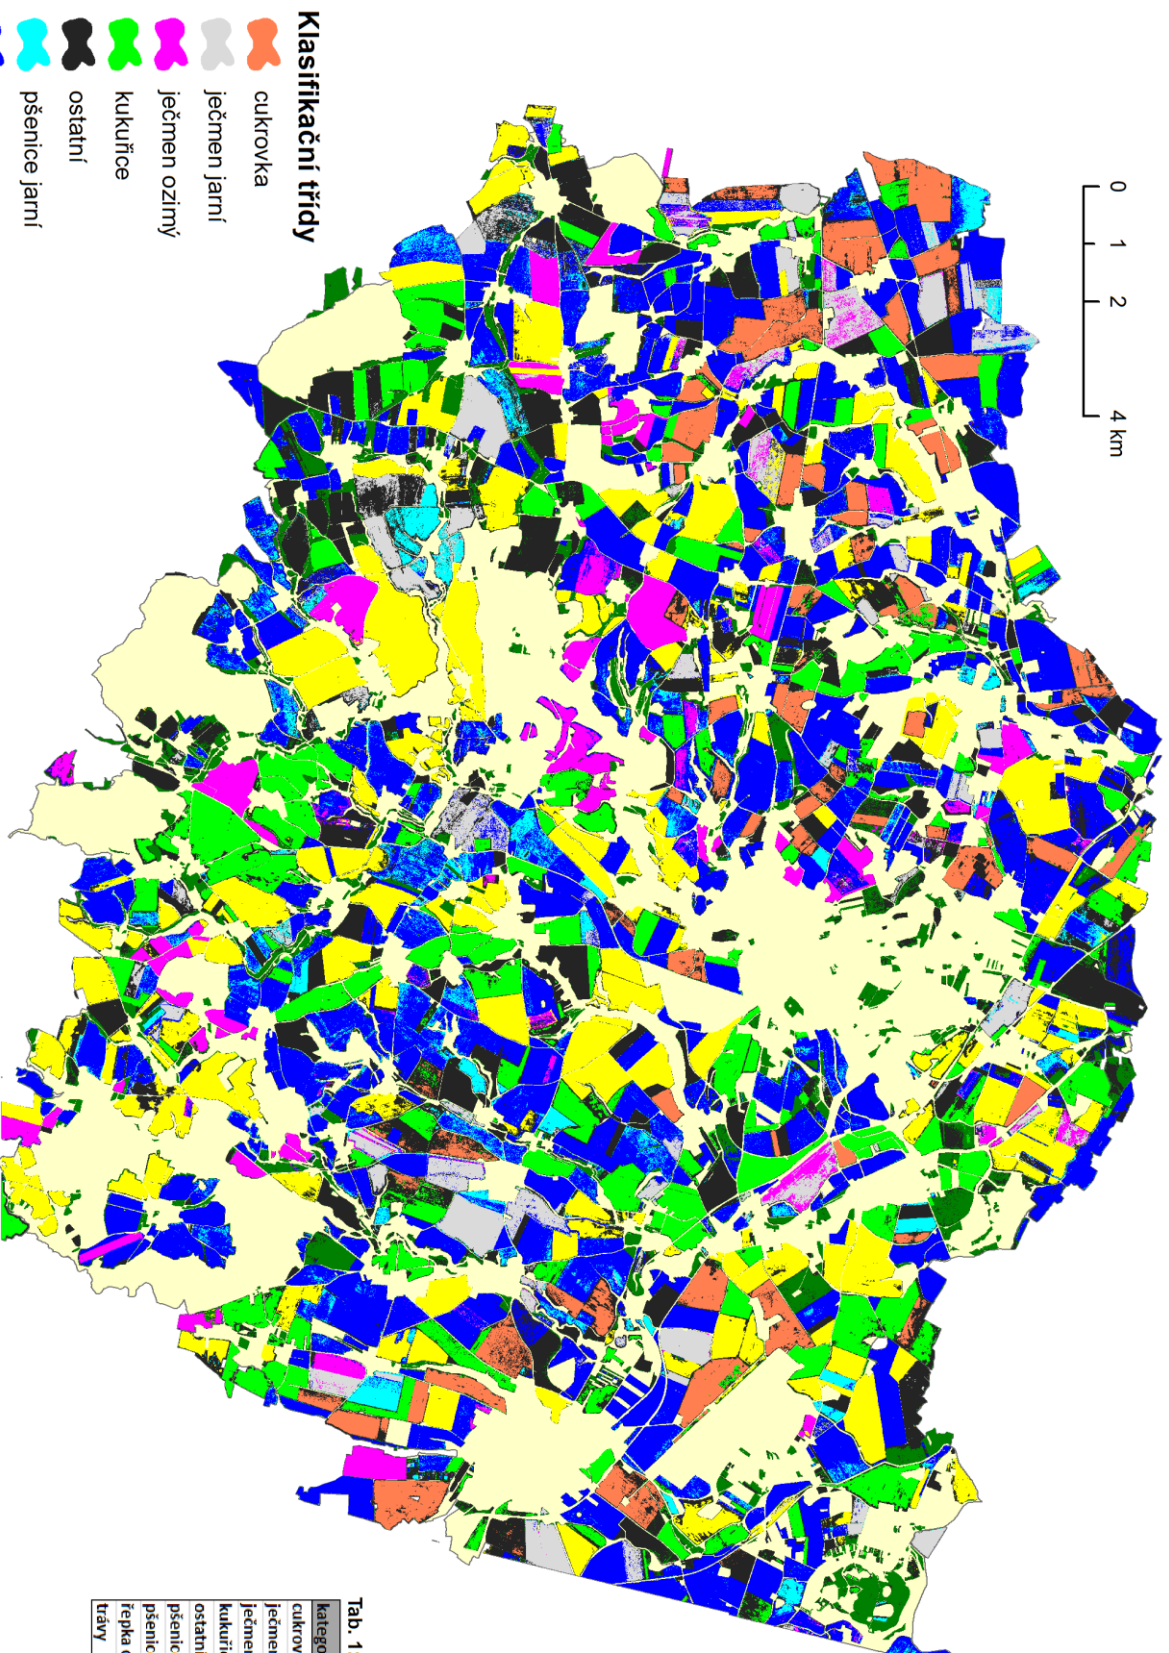

Tab. 1: rozlohy jednotlivých tříd

kategorie	rozloha v km ²	rozloha v %
cukrovka	17,26	6,92
ječmen jarní	20,32	8,15
ječmen ozimý	8,82	3,53
kukuřice	29,73	11,92
ostatní	21,06	8,44
pšenice jarní	9,64	3,86
pšenice ozimá	84,95	34,05
řepka ozimá	45,55	18,26
tráv	12,17	4,88

PIXELOVÁ KLASIFIKACE S NEJVYŠŠÍ PŘESNOSTÍ PRO PLANETSCOPE

Mapová příloha č. 3

multitemporální dataset PS, metoda ML, rok 2017



Klasifikační třídy

- cukrovka
- ječmen jarní
- ječmen ozimý
- kukuřice
- ostatní
- pšenice jarní
- pšenice ozimá
- řepka ozimá
- trávy

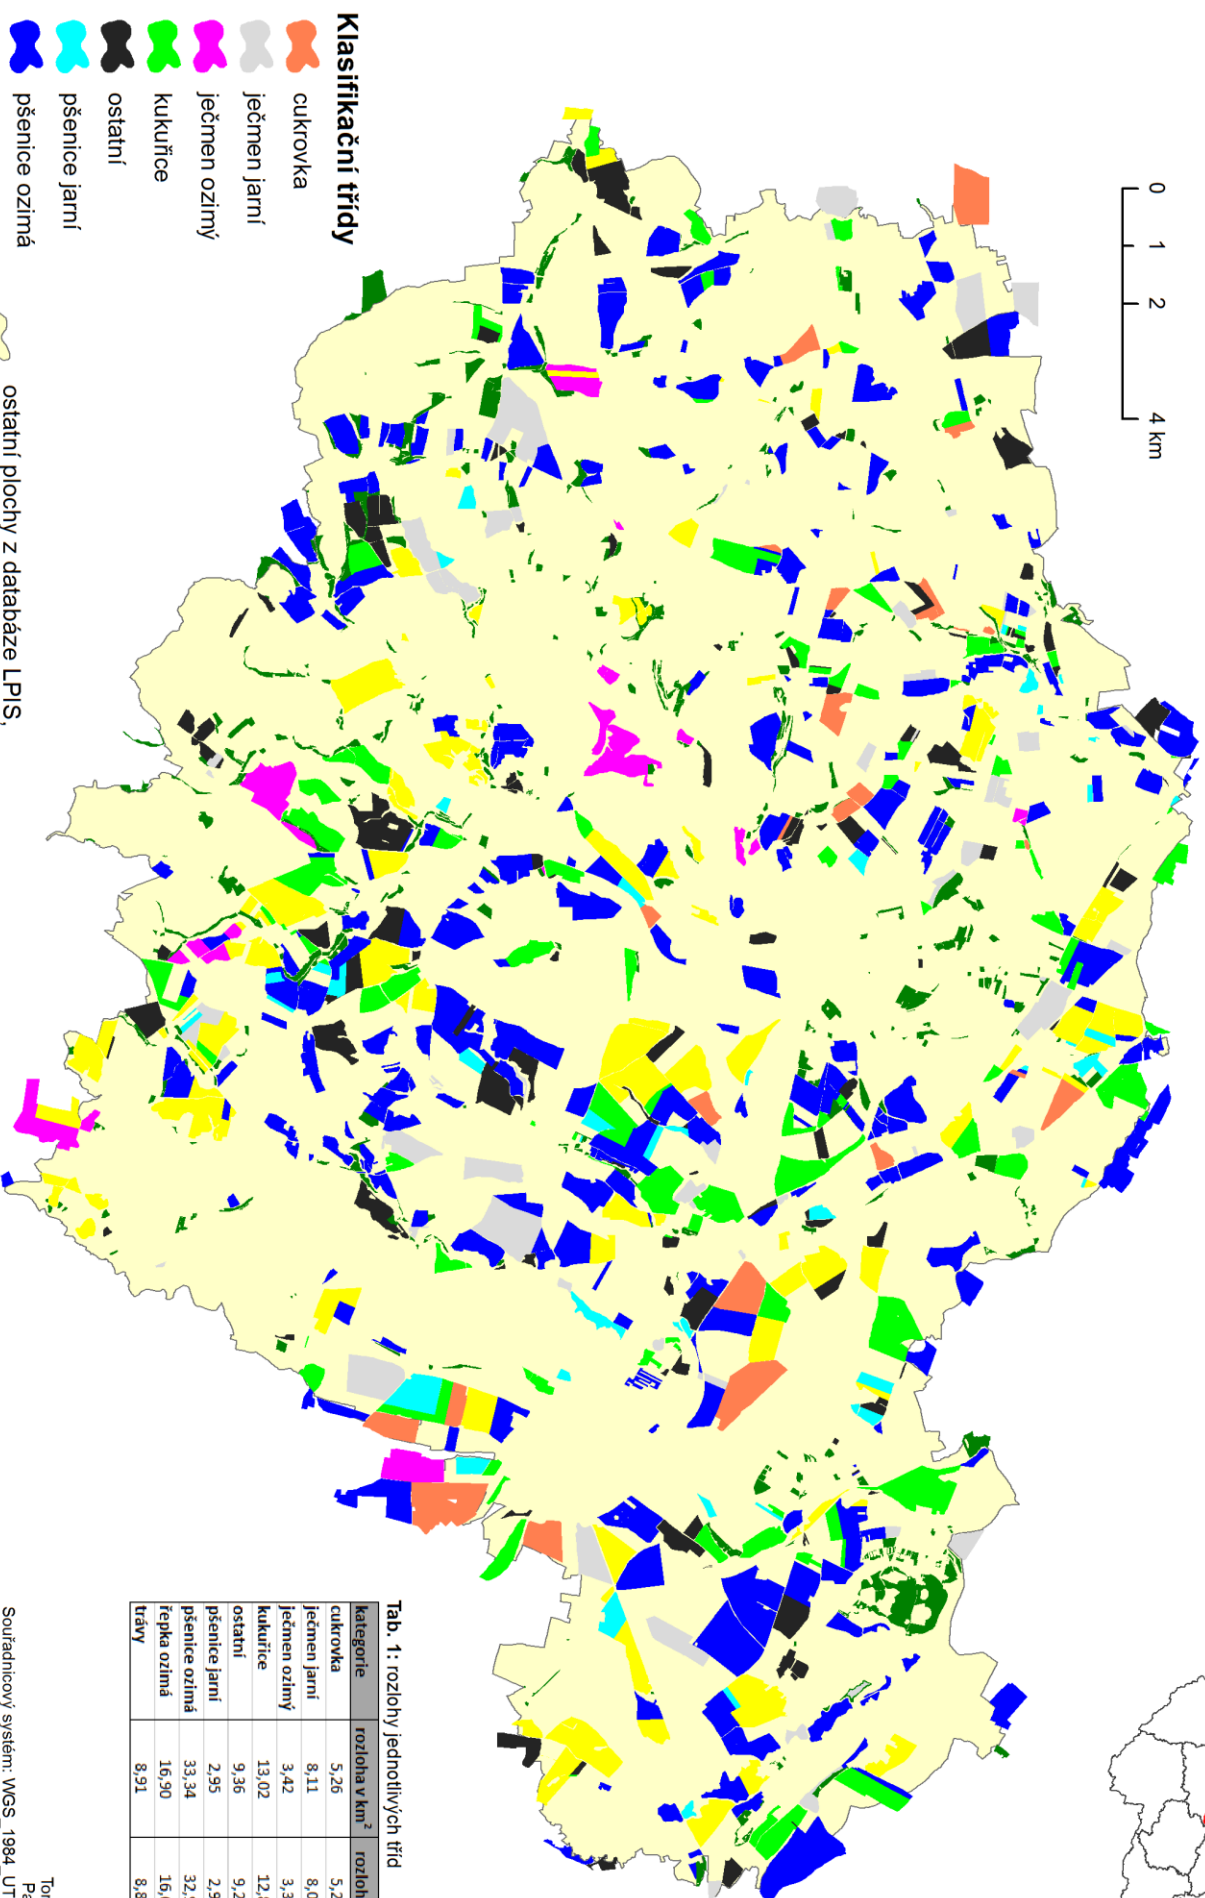
- ostatní plochy z databáze LPIs, les, zástavba, vodní plocha
- hranice území

Tab. 1: rozlohy jednotlivých tříd

kategorie	rozloha v km ²	rozloha v %
cukrovka	14,72	5,81
ječmen jarní	12,92	5,10
ječmen ozimý	11,28	4,45
kukuřice	28,36	11,19
ostatní	48,23	19,02
pšenice jarní	9,33	3,68
pšenice ozimá	70,91	27,97
řepka ozimá	40,13	15,83
trávy	17,33	6,84

LOKALIZACE PLODIN Z DATABÁZE LPIS
2017

0 1 2 4 km



Klasifikační třídy

- cukrovka
- ječmen jarní
- ječmen ozimý
- kukuřice
- ostatní
- pšenice jarní
- pšenice ozimá
- řepka ozimá
- trávy

- ostatní plochy z databáze LPIS, les, zástavba, vodní plocha
- hranice území

Tab. 1: rozlohy jednotlivých tříd

kategorie	rozloha v km ²	rozloha v %
cukrovka	5,26	5,20
ječmen jarní	8,11	8,01
ječmen ozimý	3,42	3,37
kukuřice	13,02	12,86
ostatní	9,36	9,25
pšenice jarní	2,95	2,91
pšenice ozimá	33,34	32,92
řepka ozimá	16,90	16,69
trávy	8,91	8,80

7. Diskuze

Prvním cílem práce byla analýza spektrálních charakteristik vybraných zemědělských plodin v průběhu zemědělské sezóny 2017 z časové řady dat Sentinel-2 a PlanetScope. Mezi klasifikační třídy bylo zahrnuto sedm plodin (cukrovka, ječmen jarní, ječmen ozimí, kukuřice, pšenice jarní, pšenice ozimá a řepka ozimá), třída ostatních plodin a třída trávy. Dalším cílem práce bylo provést klasifikaci těchto plodin a porovnat přesnosti pixelové a objektově orientované klasifikace pro multitemporální kompozit, případně pro snímek z období, kdy jsou od sebe jednotlivé plodiny dobře rozlišitelné.

Databáze LPIS byla brána za výchozí zdroj dat, nicméně nemusela být stoprocentně přesná, jelikož data jsou sbírána přímo od soukromých subjektů (farmáři, zemědělská družstva), kteří ne vždy poskytnou přesné rozlohy a informace o tom, jaká plodina se pěstuje na konkrétní ploše. Tento fakt mohl do určité míry ovlivnit výsledky klasifikace, protože trénovací a validační množiny byly vytvořeny na základě prostorových informací databáze LPIS. Druhou nevýhodou bylo, že v rámci DPB poskytují farmáři pouze informace o rozloze pěstované plodiny a nikoli už jejich přesné lokalizaci. DPB, u kterých bylo nahlášeno více plodin, jsem musel smazat, protože v atributových datech se u jednoho DPB vyskytovala např. pět plodin. Tím pádem jsem neznal rozmístění jednotlivých plodin v ploše DPB. Využil jsem jen plochy, kde se na jednom DPB pěstovala pouze jedna plodina. Tímto krokem jsem přišel o informace o rozmístění plodin na více než polovině území. Avšak zbylých ploch bylo dostatek, a na základě kvality získaných výsledků se dá říci, že poskytly informace dostatečné pro trénování i validaci.

Práce vycházela z předpokladu, že využití multitemporálního datasetu během jedné zemědělské sezóny by mohlo vést ke zvýšení přesnosti klasifikace vybraných tříd oproti využití snímku z jednoho termínu. Tento předpoklad se také potvrdil, jelikož nejlepších výsledků dle celkových přesností klasifikace dosáhly jednotlivé multitemporální datasety. Nejlepšího výsledku klasifikace s multitemporálním přístupem dosáhl 1. multitemporální dataset S-2 s celkovou přesností 88,4 %. Další v pořadí byl 2. multitemporální dataset S-2 s celkovou přesností 86,3 %. Nejhorší výsledek multitemporální klasifikace vykazoval multitemporální dataset PS (celková přesnost 84,85 %). Všechny tyto klasifikace byly klasifikovány metodou ML. Hlavní rozdíl mezi 1. a 2. multitemporálním datasetem spočíval ve využití tří pásem RED EDGE a dvou pásem SWIR v 1. multitemporálním datasetu. Spektrální informace z těchto pásem přinesly zlepšení přesnosti klasifikací o cca 2 %. Přínos zmíněných pásem pro zvýšení

přesnosti klasifikace dat ze S-2 popisuje ve své studii Immitzer et al. (2016). Autoři této studie také zmiňují velký vliv pásma BLUE na klasifikaci, nicméně v mých klasifikacích se to neprokázalo. Pokud totiž hodnotíme rozdíly ve spektrálních hodnotách pásem jednotlivých tříd pro S-2, u pásma BLUE nejsou v průběhu sezóny rozdílné hodnoty pro jednotlivé třídy, jako tomu je např. v případě s pásmy RED EDGE.

Pokud porovnáme výsledky obou datasetů S-2, tak vidíme, že u některých tříd vyšly lépe ZP a UP u 2. multitemporálního datasetu S-2. Pro některé třídy tak přidání pásem (RED EDGE a SWIR) přesnost klasifikace snížilo. Možná příčina nebyla nikde v literatuře popsána možná i proto, že podrobných studií s využitím dat S-2 nebylo zatím publikováno mnoho. Porovnání klasifikace 1. a 2. multitemporálního datasetu je zobrazeno v Tab. 14.

V rámci multitemporální klasifikace byly testovány i datasety tvořené NDVI a výstupy z PCA (metoda ML), které dosáhly relativně nízkých přesností. NDVI dataset u S-2 dosáhl celkové přesnosti 70,53 %, u PS 68,81 %. PCA dataset u S-2 65,01 % a u PS 62,68 %. U datasetů NDVI byly spektrální informace zjišťovány pouze z pásem RED a NIR. Zbylá pásma BLUE a GREEN a pásma RED EDGE a SWIR (u 2. multitemporálního datasetu) nesla také velké množství informací a pravděpodobně tím, že nebyla do výpočtu NDVI zahrnuta, došlo k výraznému snížení přesnosti. Osobně jsem očekával vyšší přesnost u PCA datasetů, nicméně základě výsledků bych tuto metodu nedoporučil, protože nepřináší potřebnou přesnost.

Nejvyšších ZP a UP přesností u multitemporálních klasifikací dosáhly třídy řepka ozimá, cukrovka a kukuřice. Vysokou klasifikační přesnost u řepky ozimé bych odůvodnil časným nástupem hlavní vegetační fáze, a to už koncem dubna. Ostatní plodiny jsou v tu dobu v raných fázích a mají menší množství zelené biomasy a řepka je tudíž od nich dobře odlišitelná. Druhým důvodem je také období kvetení, které se projevuje v polovině května, kdy došlo k výrazně změně spektrálních hodnot, a tím pádem byla řepka velmi dobře odlišitelná. U cukrovky hlavní důvod vidím v dlouhém hlavním vegetačním období, které trvá od poloviny června do poloviny října. Cukrovka si tak udržuje konstantní vysoké hodnoty NDVI a v srpnových termínech je dobře odlišitelná od plodin, které jsou již sklizeny. U kukuřice spatřuji hlavní výhodu vedoucí k dobré odlišitelnosti ve velmi pozdním nástupu hlavní vegetační fáze (viz Tab. 12), která začíná až začátkem července. V období od konce dubna až do června dosahuje velmi nízkých NDVI hodnot oproti většině plodin, které už jsou vzrostlé a tím pádem je dobře odlišitelná. To samé platí i v srpnových termínech, kdy většina plodin je již sklizena, ale kukuřice dosahuje vrcholu hlavní vegetační fáze a opět je v tomto období dobře odlišitelná.

Nejhůře klasifikované plodiny patří pšenice jarní a také skupina ostatních plodin. U kategorie ostatních plodin se daly tyto výsledky očekávat, jelikož je tvořena z několika různých plodin, které se v území vyskytovaly ve velmi malé míře. Tím pádem došlo ke zkombinování spektrálních příznaků více plodin a tato kategorie pak mohla jevit podobný spektrální průběh jako některá z dalších tříd. Z chybových matic vyplývá, že tato třída byla nejvíce zaměňována s třídami kukuřice, pšenice jarní a pšenice ozimá. Avšak k záměně u kategorie ostatních plodin došlo prakticky se všemi třídami. U pšenice jsou nízké hodnoty ZP a UP způsobeny častými záměnami zejména s plodinami ječmen jarní, pšenice ozimá a s třídou ostatních plodin. Je to způsobeno podobným spektrálním průběhem těchto tříd (především s pšenicí ozimou). Pokud se podíváme na průběh fenofází (viz Tab. 12), tak vidíme, že pšenice jarní i ozimá mají velice podobný vrchol vegetační fáze. Mnohem lépe to je vidět z grafů hodnot NDVI a DN (viz Graf 6 a Graf 7), kde obě plodiny mají téměř stejný spektrální průběh a jsou od sebe špatně odlišitelné. Zheng et al. (2015), kteří provedli klasifikaci plodin kukuřice, pšenice ozimé a ječmene ozimého, zmiňují, že nejhůře od sebe separovatelné jsou plodiny pšenice ozimá a ječmen ozimý, protože mají podobný spektrální průběh.

Nejvyšší přesnosti klasifikace v rámci monotemporálního přístupu (metoda ML) bylo dosaženo z dat S-2 z termínu 20. 6. 2017 (celková přesnost 76,19 %) a z dat PS z termínu 3. 6. 2017 (celková přesnost 67,13 %). Tento výsledek se dal předpokládat už z průběhu hodnocení trénovacích dat, protože červnové termíny vykazovaly nejlepší separabilitu trénovacích množin (viz Tab. 9). Pokud se podíváme na graf popisující spektrální hodnoty pásem jednotlivých tříd pro S-2 (viz Graf 11), tak vidíme, že u obou červnových termínů jsou jednotlivé křivky od sebe nejvíce navzájem vzdáleny, protože mají více rozdílné hodnoty než v jiných termínech a díky tomu lze očekávat nejlepší odlišitelnost. Z výsledků pro další monotemporální termíny také vyplynulo, že nejnižších přesností bylo dosaženo ke konci srpna. U dubnových či květnových termínů byla přesnost vyšší (v průměru o 10 %) ve srovnání se srpnovými termíny. Tento výsledek koresponduje ze studií od Vuolo, et al. (2018), kteří zmiňují, že období jara (březen až duben) není vhodné pro rozeznání plodin, jelikož vegetace teprve začíná růst a naopak v průběhu vrcholu vegetační sezóny (červen) bylo nevhodnější období pro diferenciaci plodin. Výjimku tvoří třída trávy. U všech termínů monotemporální klasifikace dosahovala v případě dat S-2 vysokých přesností, a to 80 – 90 % (viz Tab. 25 v přílohách). U dat PS tento jev není znatelný. Nejvyšší ZP a UP dosáhla tato třída v červnu. Právě v tomto období došlo ke kosení a díky tomu ke snížení biomasy a k významné změně NDVI, což vedlo k lepšímu odlišení třídy trávy od ostatních tříd.

Srpnové termíny se jeví jako nejhorší z toho důvodu, že již je období sklizně a plochy po sklizni se jeví jako téměř holá půda s minimem vegetace, jsou i podobné, a tím pádem je v tomto období již špatná odlišitelnost. Výjimkou je třída kukuřice, která v srpnových termínech dosahuje v rámci monotemporálního přístupu nejvyšší přesnosti (viz Tab. 25 v přílohách), jelikož má výrazně posunuté hlavní vegetační období ke konci zemědělské sezóny. Brzké jarní termíny (březen, duben, květen) jsou zase počáteční fáze růstu, takže se také očekává nižší přesnost klasifikace. Nicméně pro některé ozimé plodiny (řepka ozimá) bylo dosaženo nejvyšší klasifikační přesnosti v květnovém termínu (hlavně u dat S-2) a poté se již klasifikační přesnost snižovala. Velký vliv na tento výsledek mělo již zmiňované kvetení.

Podstatný rozdíl je taky v obou nejvyšších přesnostech u dat S-2 a PS (76,19 % vs. 67,13 %). Zde hrála významnou roli pásma RED EDGE a SWIR, kterými disponuje S-2. Díky těmto pásmům bylo dosaženo o téměř 10 % vyšší celkové přesnosti ve prospěch S-2. Výsledky práce ukazují, že vliv těchto pásem je u monotemporálního přístupu mnohem větší (zvýšení přesnosti o cca 10 %) než u multitemporálního přístupu (zvýšení přesnosti o 2 %).

Pokud porovnám multitemporální a monotemporální klasifikaci, tak jednoznačně lépe se jeví multitemporální přístup, který dosáhl o více než 12 % vyšší celkové klasifikační přesnosti u pixelových klasifikací S-2 a o 19 % vyšší přesnosti u klasifikací PS. Jako nejvhodnější termín pro monotemporální přístup bych zvolil červnový termín, kde bylo dosaženo nejvyšších celkových přesností. Obecně červnové termíny považuji za klíčové pro tvorbu multitemporálního kompozitu, jelikož poskytují dobrou odlišitelnost plodin. Otázkou je, jakých přesností by dosáhly termíny z července, které nebyly do klasifikací začleněny, jelikož obsahovaly velké množství oblačnosti. V datech jsem právě tyto termíny postrádal (poslední termín v datech S-2 byl z 20. 6. a následující až 7. 8., u PS pak poslední termín z 22. 6. a další 31. 7.), jelikož si myslím, že jsou klíčové pro diferenciaci plodin, protože v tomto období u některých plodin dochází ke sklizni a jiné ještě stále pokračují v hlavní vegetační fázi. Díky nim mohlo být dosaženo vyšší celkové přesnosti jak v rámci klasifikace multitemporálního kompozitu, tak i u klasifikace z jednoho termínu. Nicméně díky kombinovaným grafům jsem tuto časovou mezeru vyplnil červencovými termíny z let 2015 a 2016 a alespoň pro zjištění spektrálních příznaků jsem získal požadované informace.

Co se týče porovnání pixelové a objektové klasifikace navzájem, tak bylo dosaženo velmi podobných výsledků u obou typů klasifikací. Nejlepší výsledek pixelové klasifikace byl dosažen u 1. multitemporálního datasetu S-2 (celková přesnost 88,4 %) a nejlepší výsledek objektové klasifikace byl dosažen u 2. multitemporálního datasetu S-2 (celková přesnost

87,29 %). Detailnější porovnání ZP a UP jednotlivých tříd je v Tab. 20. Z tabulky vidíme, že téměř každá třída dosáhla lepších ZP a UP v z každé ze dvou klasifikací (pixelové, objektové). Výjimkou jsou ale nejlépe klasifikované plodiny (zmněno výše) jako řepka ozimá a kukuřice, které byly s vyšší přesností klasifikovány s využitím pixelové klasifikace. Určitou roli v tom, že byly některé plodiny s vyšší přesností klasifikovány objektovým přístupem, může hrát využití texturálních příznaků. Objektová klasifikace se ukazuje vhodná pro problematické třídy pšenice jarní a ostatní plodiny, jelikož se jejich vyklasifikované rozlohy u objektových klasifikací (u S-2 i u PS) více blížily rozlohám těchto tříd v databázi LPIS. Významným zjištěním je, že nejlépe vyklasifikované plodiny (řepka ozimá, kukuřice a cukrovka), dosáhly nejvyšších ZP a UP ze všech plodin v případě obou typů klasifikací.

Další část diskuze bych věnoval porovnání klasifikačních metod. V práci byly využity metody ML a SVM pro pixelové klasifikace a SVM, KNN a PCA u objektové klasifikace. Výsledky všech klasifikačních metod a jejich přesnosti jsou znázorněny v Tab. 24 v přílohách. U pixelové klasifikace se jako lepší jevila metoda ML (nejvyšší celková přesnost 88,4 %). Jelikož trénovací množiny obou typů dat, jak S-2, tak PS měly normálnímu rozdělení (viz Graf 1), tak se daly tyto výsledky očekávat. Metody SVM s využitím jádrové funkce *radial basis* vykazovaly o cca 4 % nižší přesnost. U objektové klasifikace vyšla nejlépe metoda SVM (nejvyšší celková přesnost 87,29 %), konkrétně s funkcí *radial basis* (v případě multitemporálního datasetu PS vyšla lépe metoda SVM s polynomičkou jádrovou funkcí). Dále následovaly metody KNN (průměr přesností cca 75 – 80 %) a PCA. Zajímavostí je velký rozdíl mezi celkovou přesností u metody SVM *sigmoid* v rámci 1. a 2. multitemporálního datasetu S-2 (30 % vs. 79 %). Vysoký počet šedesáti pásem u 1. multitemporálního datasetu oproti dvaceti čtyř pásem u 2. multitemporálního datasetu S-2 byl pravděpodobně pro tuto metodu nevhodný.

Klíčovým faktorem k odlišitelnosti plodin bylo definování a sledování fenofází na základě spektrálního průběhu (viz Tab. 12). Fenofáze byly definovány na základě interpretace grafů hodnot NDVI a DN (pro S-2) a NDVI hodnot pro PS. Fenofáze definované v práci pro jednotlivé plodiny na základě analýzy spektrálních dat odpovídaly do značné míry předpokládanému průběhu fenofází uvedenému v literatuře (Waldhoff, Lussem, Bareth, 2017, Bargiel, 2017, Zheng et al., 2015), což dokazuje správnost postupu. Z použitých družicových dat bylo také zjištěno, že v roce 2017 byly termíny sklizně ječmene jarního a pšenice ozimé o cca dva týdny dříve, než je pro tyto plodiny typické, jak se udává v literatuře (Agromanual, 2018; MENDELU, 2018). Důvod, proč tomu tak bylo, byl zmíněn v kapitole 6.2.

Z výsledků práce byla odvozena období relativně dobré odlišitelnosti jednotlivých plodin (jsou zjištěny z průběhu fenofází a grafů) viz Tab. 22. Dva časově oddělené termíny odlišitelnosti má třída trávy (první termín je z důvodu kosení a druhý termín díky vegetačnímu vrcholu, který se projevuje vysokou hodnotou NDVI).

Tab. 22: Termíny odlišitelnosti jednotlivých plodin

třída	Termíny odlišitelnosti					
	duben	květen	červen	červenec	srpen	září
cukrovka						
ječmen jarní						
ječmen ozimý						
kukuřice						
pšenice jarní						
pšenice ozimá						
řepka ozimá						
trávy						
 termín odlišitelnosti					

Termíny z tabulky 22 se shodují s termíny, které uvádí několik autorů různých studií. V případě práce Bargiel (2017) byl termín odlišitelnosti pro kukuřici srpen, pro cukrovku červen až září. Shoda je i s výsledky autorů Pan et al. (2015), kteří stanovili termín odlišitelnosti pro kukuřici na srpen, pro pšenice ozimou na přelom dubna až května. Zheng et al. (2015) uvádí jako termín odlišitelnosti pro pšenici ozimou přelom dubna a května. Belgiu, Csillik (2018) určili termín odlišitelnosti pro kukuřici na přelom července a srpna, pro pšenici ozimou květen a pro ječmen ozimý též květen. A nakonec Waldhoff, Lussem, Bareth (2017) uvádí jako termín odlišitelnosti pro kukuřici srpen až září, pro cukrovku též srpen až září, pro ječmen jarní červen až červenec a pro ječmen ozimý červen.

Oproti studii Zheng et al. (2015) se termíny mírně rozcházejí u plodiny kukuřice (pro niž tito autoři určili termín odlišitelnosti červen až červenec. Odlišnost byla zaznamenána také u pšenice ozimé oproti studii Waldhoff, Lussem, Bareth (2017), kteří datovali termín odlišitelnosti na měsíc červen.

Termíny odlišitelnosti zjištěné v této práci se ve většině případů shodují s termíny uváděnými v literatuře a lze tedy usuzovat, že postup v této práci byl správný.

Výsledky svých klasifikací jsem porovnal s dostupnými výsledky z literatury, která je uvedena v kapitole 2.6. Jedná se o studie, ve kterých se autoři zabývali klasifikací zemědělských plodin podobnými metodami. Byly porovnány nejlepší výsledky pixelových klasifikací, objektových klasifikací a také výsledky monotemporálních pixelových klasifikací (viz Tab. 23). Vždy je popsán zdroj a typ dat, klasifikační metoda, CP, ZP a UP. U monotemporálních klasifikací i časový termín. Světle červenou barvou jsou zvýrazněny

nejlepší ZP a světle modrou UP. V místech, kde jsou otazníky, nebylo možné dohledat konkrétní přesnost. V případě prázdných míst jsem v literatuře žádná výsledky pro danou plodinu nenašel. Ve srovnání s literaturou jsem dosáhl vyšších ZP a UP převážně u monotemporálních pixelových klasifikací. Nicméně porovnání výsledků je potřeba brát

Tab. 23: Porovnání klasifikačních přesností se zdroji literatury

Porovnání pixelových klasifikací									
zdroj	mé výsledky S-2	mé výsledky PS	Belgiu, Csillik, 2018	Zheng et al., 2015	Bargiel, 2017	Sonobe et al., 2018	Mondal et al., 2014	Masseey et al., 2017	Vuolo et al., 2018
typ dat	multispektrální	multispektrální	multispektrální	multispektrální	radarová	multispektrální	multispektrální	multispektrální	multispektrální
metoda	ML	ML	RF	SVM rbf	ML	support learner	statistický	decision trees	RF
CP (%)	88,4	84,85	97,14	90,00	?	91,60	86,08	77,60	96,00
trída	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)
cukrovka	90,13	98,31	76,17	98,02					
ječmen jarní	71,93	98,46	66,50	90,50	0,00	100,00			
ječmen ozimý	85,88	92,77	97,84	60,74	80,30	99,10			
kukuřice	86,83	99,93	92,66	98,14	89,04	94,20	96,00	96,00	86,30
ostatní	67,84	50,34	79,32	48,85	89,00	70,00	93,90	84,60	83,60
pšenice jarní	27,35	35,53	28,34	14,64					
pšenice ozimá	93,54	92,16	85,98	95,28	100,00	100,00			
řepka ozimá	97,27	98,86	94,80	99,32					
trávy	95,02	83,83	84,17	85,49					

Porovnání objektových klasifikací									
zdroj	mé výsledky S-2	Belgiu, Csillik, 2018							
typ dat	multispektrální	multispektrální							
metoda	SVM rbf	RF							
CP (%)	87,29	97,62							
trída	ZP (%)	UP (%)	ZP (%)	UP (%)					
cukrovka	95,97	82,68							
ječmen jarní	80,39	89,86							
ječmen ozimý	96,23	56,73							
kukuřice	83,65	95,81	94,52	93,24					
ostatní	52,69	66,49							
pšenice jarní	33,28	14,80	100,00	100,00					
pšenice ozimá	92,38	96,27							
řepka ozimá	96,60	94,93							
trávy	95,06	81,19							

Porovnání pixelových monotemporálních klasifikací									
zdroj	mé výsledky	?	Vaudour et al., 2015	02.03.2013	srpen 2015	Vuolo et al., 2018			
typ dat	multispektrální	multispektrální	multispektrální	multispektrální	multispektrální	multispektrální			
metoda	ML	SVM rbf	SVM polynomial	RF	RF	RF			
CP (%)	76,19	87,46	84,80	83,20	80,00				
trída	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)
cukrovka	79,34	95,87			83,70	73,10	?	?	?
ječmen jarní	71,58	67,60							
ječmen ozimý	95,37	47,17			87,00	69,90			
kukuřice	85,64	95,09	?	?			81,00	77,70	?
ostatní	53,74	40,42			85,00	87,80			
pšenice jarní	38,90	8,06							
pšenice ozimá	68,80	94,01			79,10	81,20			
řepka ozimá	92,95	99,38			72,30	88,90			
trávy	89,57	74,69							

s rezervou, jelikož se v publikacích ne vždy klasifikovaly všechny plodiny, které jsem klasifikoval v této práci (klasifikovaly se i jiné typy plodin a povrchů). Závěrečné porovnání je spíše pro představivost, jelikož klasifikace probíhaly na různých místech (vliv klimatu, zeměpisná šířka, typ půdy, ...) a vycházelo se z různých typů dat a metod.

Rozdíly ve vlastnostech využitých dat S-2 a PS (spektrální a prostorové rozlišení) vedly k otázce, zda ke zvýšení přesnosti klasifikace, přispěje spíše větší počet pásem, resp. zastoupení pásem důležitých pro klasifikaci vegetace (RED EDGE) a S-2, nebo lepší prostorové rozlišení dat PS (pixel o velikosti 10 m u S-2 a u PS 3,125 m). Z výsledků vyplynulo, že pro zvýšení přesnosti klasifikace měla důležitou roli pásma RED EDGE, případně SWIR u S-2. Lepší prostorové rozlišení dat PS s pásmy RGB a NIR přineslo horší výsledky jak celkové klasifikace, tak klasifikace jednotlivých plodin. Lze říci, že práce ukázala, že mnohem větší vliv na celkový výsledek klasifikace (na zlepšení její přesnosti) má vyšší spektrální rozlišení S-2 a nikoliv větší prostorové rozlišení dat PS. Původně jsem očekával opačný průběh, ale nakonec byl tento předpoklad vyvrácen na základě popsanych výsledků klasifikací. V případě této práce nemělo menší prostorové rozlišení S-2 vliv na celkové výsledky. Podobnou otázku řešili ve své studii Psomiadis et al., 2017, kteří porovnávali klasifikaci plodin z indexů LAI a NDVI pro bavlnu, pšenici jarní a pšenici ozimou z dat S-2 a WorldView (prostorové rozlišení – 2 m). Z detailnější analýzy na základě koeficientu determinace R^2 vyplynulo, že oba typy dat dávají porovnatelné výsledky navzdory tomu, že S-2 má mnohem menší prostorové rozlišení než WV-2. Tento fakt z části dokazuje i moje tvrzení, že rozdíl v prostorovém rozlišení (10 m vs. 3,125 m) neměl zásadní vliv na výsledky klasifikace, což především dokazuje Tab. 27 v přílohách, kde je porovnávána pixelové klasifikace 2. multitemporálního datasetu S-2 a multitemporálního datasetu PS, přičemž oba datasety disponují stejným spektrálními pásmy RGB a NIR a výsledky i přes větší prostorové rozlišení PS vyzněly lépe pro S-2 o cca 1,5 %.

Pokud se týká rozdílných výsledků klasifikací S-2 a PS, určitou roli mohl hrát i jiný počet a nepatrně rozdílná data termínů, ze kterých byly vytvořeny multitemporální datasety. Multitemporální datasety S-2 tvořilo celkem šest snímků z období 1. 4. až 29. 8. a multitemporální datasety PS tvořilo sedm snímků z období 11. 5. až 30. 8. Zásadní rozdíl je tedy v kratší časové řadě datasetu PS o více než jeden měsíc. Toto zkrácení mohlo mít také vliv na přesnosti klasifikací. Žádný bezoblačný a dostatečně velký snímek, který by pokrýval testované území z dubna, nebyl ale pro dataset PS dostupný. V práci byly využity bezoblačné dostupné snímky z dat S-2 pokrývající celé území a z dat PS, které pokrývaly více než 90 % testovaného území. Původně jsem zamýšlel vytvořit multitemporální datasety dohromady z let

2015, 2016 a 2017, nicméně toto nebylo možné, jelikož se ve většině případů na stejné ploše pěstuje každý rok jiná plodina. Také jsem předpokládal, že budu moci pro práci využít hustší časovou řadu snímků PS, jelikož se ve zdrojích píše, že perioda snímání stejného území, je díky velkému množství družic PS pouze jeden den. Pokrytí území ale přesto nebylo úplné a množství termínů obsahovalo velké množství oblačnosti.

8. Závěr

V práci byly analyzovány spektrální příznaky vybraných zemědělských plodin v datech Sentinel-2 a PlanetScope s cílem určit vhodný termín pro rozlišení plodin. Dalším cílem bylo zjistit, který z klasifikačních přístupů (monotemporální vs. multitemporální, resp. pixelový vs. objektově orientovaný) přinese v případě zemědělských plodin přesnější výsledky. Zároveň byla také porovnána přesnost klasifikace při použití dvou typů dat s rozdílným prostorovým a spektrálním rozlišením.

Pro analýzu byla využita data z multispektrálních družic S-2 a PS z roku 2017 (pro účely klasifikace) a 2015, 2016 a 2017 pro účely zjištění spektrálních příznaků. S-2 disponuje deseti spektrálními pásmy (RGB, RED EDGE 1, 2, 3, NIR 1, 2 a SWIR 1, 2) a prostorovým rozlišením 10 m. PS má čtyři spektrální pásma (RGB a NIR) a rozlišení 3,125 m. Přesnějších výsledků bylo dosaženo pro data S-2, která mají horší prostorové, ale významně lepší spektrální rozlišení.

Z výsledků analýzy spektrálních příznaků jednotlivých tříd vyplývá, že nejlepší termín odlišitelnosti je pro cukrovku v období červen až září, pro ječmen jarní první polovina června, pro ječmen ozimý přelom května a června, pro kukuřici konec srpna, pro pšenici jarní první polovina května, pro pšenici ozimou první polovina května, pro řepku ozimou polovina května a pro trávy první polovina května a konec června.

Dobré odlišitelnosti dosáhla kukuřice od ječmene ozimého a od pšenice jarní, jelikož se vrcholy jejich hlavní vegetační fáze míjejí. Naopak nejhůře odlišitelná na základě fenofází byla dvojice plodin ječmen ozimý a pšenice ozimá, což ve své studii potvrzuje i Zheng et al. (2015).

Z klasifikačních výsledků vyplývá, že multitemporální přístup je pro klasifikaci zemědělských plodin mnohem přesnější než klasifikace z jednoho časového termínu. Dokazují to celkové přesnosti (nejlepší multitemporální klasifikace dosáhla 88,4 % a nejlepší monotemporální klasifikace z 20. 6. dosáhla 76,19 %). V obou případech z dat S-2. Nepatrně lepších výsledků dosáhla pixelová klasifikace ve srovnání s objektovou klasifikací (nejlepší pixelová klasifikace 88,4 %, nejlepší objektová klasifikace 87,29 %). Opět v obou případech z dat S-2. Nejvyšších ZP a UP přesností dosáhly třídy řepka ozimá, cukrovka a kukuřice, naopak mezi nejhůře klasifikované plodiny patří pšenice jarní a také skupina ostatních plodin.

Ve srovnání s literaturou jsem nedosáhl vyšší přesnosti, než byl nejlepší výsledek uvedený v práci Belgiu, Csillik (2017), nicméně porovnání celkových přesností je diskutabilní, jelikož byly vždy klasifikovány i jiné plodiny. Na druhou stranu jsem ale ve srovnání s dostupnou

literaturou dosáhl lepších ZP u plodin ječmen ozimý, kukuřice a řepka ozimá a lepších UP u plodin cukrovka, kukuřice, pšenice ozimá a řepka ozimá v rámci monotemporálního přístupu.

Za hlavní úskalí multitemporálních klasifikací lze označit omezenou dostupnost bezoblačných snímků. Z důvodu výskytu oblačnosti v datech jsem postrádal termíny mezi druhou polovinou června a začátkem srpna. Právě snímky z toho termínu mohly pravděpodobně ještě zvýšit klasifikační přesnost. Podrobnější časovou řadu jsem očekával především u dat PS (časová perioda snímání stejného území je jeden den).

Druhým problémem byla ztráta některých ploch z databáze LPIS kvůli nepřesné lokalizaci plodiny na konkrétní části plochy. Trénovacích a validačních dat byl ale i přesto dostatek. Možnost využít pro práci databázi LPIS zcela jistě přispěla k dobrým výsledkům klasifikace.

Diplomová práce splnila veškeré cíle, které byly stanoveny. Byly zjištěny spektrální příznaky plodin a jejich termíny odlišitelnosti. Byly také nalezeny odpovědi na otázky, zda je vhodnější pro tyto účely multitemporální nebo monotemporální přístup, zdali je lepší pixelová či objektově orientovaná klasifikace. Na základě výsledků práce bych pro účely klasifikace zemědělských plodin doporučil využít multitemporální dataset dat Sentinelu-2 a pixelovou klasifikaci.

Návrhem pro možné pokračování v tomto tématu by bylo využití radarových dat Sentinel-1 ke klasifikaci zemědělských plodin a také jejich porovnání s optickými daty družice Sentinel-2.

POUŽITÉ ZDROJE INFORMACÍ

Agromanual, 2018. Ječmen jarní [online]. [cit. 7. 9. 2018]. Dostupné z: <https://www.agromanual.cz/cz/atlas/plodiny/plodina/jecmen-jarni>

Baatz, M., Schäpe, A., 2000. Multiresolution Segmentation – an optimization approach for highquality multi-scale image segmentation. *Angewandte Geographische Informations-Verarbeitung* [online]. 12, str. 12-23 [cit. 17. 8. 2018]. Dostupné z: http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf

Bargiel, D., 2017. A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sensing of Environment* [online]. 198, str. 369-383 [cit. 21. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0034425717302821>

Belgiu, M., Csillik, O., 2018. Sentinel-2 cropland mapping using pixel-based and object-based timeweightd dynamic time warping analysis. *Remote Sensing of Environment* [online]. 204, str. 509-523 [cit. 24. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0034425717304686>

ČHMÚ, 2018. Průměrná měsíční teplota vzduchu ve srovnání s normálem 1981–2010 na území ČR a jednotlivých krajů [online]. [cit. 1. 12. 2018]. Dostupné z: <http://portal.chmi.cz/historicka-data/pocasi/uzemni-teploty>

ČVUT, 2018. Distribuční funkce standardního normálního rozdělení [online]. [cit. 3. 11. 2018]. Dostupné z: https://mat.fsv.cvut.cz/hala/files/Distribucni_funkce_standardniho_normalniho_rozdeleni.pdf

Dobrovolný, P., 1998. Dálkový průzkum Země: Digitální zpracování obrazu. Brno: Přírodovědecká fakulta Masarykovy univerzity. 1. vyd. 210 str. ISBN 80-210-1812-7.

GISAT, 2017. Sentinel-2 A [online]. [cit. 15. 9. 2018]. Dostupné z: <http://www.gisat.cz/content/cz/dpz/prehled-druzicovych-systemu/satelite/sentinel-2-a>

Halounová, L., Pavelka, K., 2005. Dálkový průzkum Země. Praha: České vysoké učení technické. 1. vyd. 192 str. ISBN 978-80-01-03124-7.

Harris Geospatial Solutions, 2018. Region of Interest (ROI) Tool [online]. Dostupné z: <https://www.harrisgeospatial.com/docs/RegionOfInterestTool.html>

HPS, 2018. Cukrová řepa [online]. [cit. 7. 9. 2018]. Dostupné z: <http://www.hps.cz/cukrova-repa/>

Huang, C., Davis, S. L., Townshend, G. R. J., 2002. An assessment of support vector machines for land cover classification. *INT. J. REMOTE SENSING* [online]. 23(4), str. 725-749 [cit. 13. 8. 2018]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.134.4958&rep=rep1&type=pdf>

Immitzer, M. et al., 2016. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. *Remote Sensing* [online]. 8(3), str. 166-192 [cit. 13. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/295845441_First_Experience_with_Sentinel-2_Data_for_Crop_and_Tree_Species_Classifications_in_Central_Europe

IS MUNI, 2006. Support vector machines (SVM) [online]. [cit. 13. 8. 2018]. Dostupné z: https://is.muni.cz/el/1433/podzim2006/PA034/09_SVM.pdf

Jayawardhana, N. N. G. W., Chathurange, I. M. V., 2015. Extraction of agricultural phenological parameters of Sri Lanka using MODIS, NDVI time series data. *Procedia Food Science* [online]. 6, str. 235-241. [cit. 22. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S2211601X16000286>

Jensen, R. J., 2005. Introductory Digital Image Processing: A Remote Sensing Perspective. Upper

Saddle River, N.J: Prentice Hall. 3. vyd. 544 str. ISBN 978-0131453616.

Kondratyev, YA. K., Fedchenko, P. P., 1981. RECOGNITION OF SOME CROPS FROM THEIR REFLECTION SPECTRA. *Advances in Space Research* [online]. 1(10), str. 87-88 [cit. 23. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/0273117781903835>

Lantzanakis, G., Mitraka, Z., Chrzsoulakis, N., 2016. Comparison of physically and image based atmospheric correction methods for Sentinel-2 satellite imagery. *Perspectives on Atmospheric Sciences* [online]. str. 255-261 [cit. 19. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/306117820_Comparison_of_physically_and_image_based_atmospheric_correction_methods_for_Sentinel-2_satellite_imagery

Lu, D. et al., 2004. Change Detection Techniques. *International Journal of Remote Sensing* [online]. 25(12), str. 2365-2401 [cit. 19. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/235245895_Change_Detection_Techniques

Mangiarotti, S. et al., 2017. Can the global modeling technique be used for crop classification?. *Chaos, Solitons & Fractals* [online]. 106, str. 363-378. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0960077917305040>

Massey, R. et al., 2017. MODIS phenology-derived, multi-year distribution of conterminous U.S. crop types. *Remote Sensing of Environment* [online]. 198, str. 490-503 [cit. 22. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0034425717302924>

Meier, U., BLEiholder, H., 2006. Growth stages of mono-and dicotyledonous plants. BBCH Monograph [online]. *Federal Biological Research Centre for Agriculture and Forestry*. 2. vyd. 158 str. Dostupné z: <https://www.politicheagricole.it/flex/AppData/WebLive/Agrometeo/MIEPFY800/BBCHengl2001.pdf>

MENDELU, 2018. Termíny setí a sklizně [online]. [cit. 7. 9. 2018]. Dostupné z: <http://user.mendelu.cz/xvaltyni/systemy/projekt/files/03-op-soubory/Terminy-seti-a-sklizne.pdf>

Mondal, S. et al., 2014. Extracting seasonal cropping patterns using multitemporal vegetation indices from IRS LISS-III data in Muzaffarpur District of Bihar, India. *The Egyptian Journal of Remote Sensing and Space Science* [online]. 17(2), str. 123-134 [cit. 22. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S111098231400026X>

Moran, S. M., Inoue, Y., Barnes, M. E., 1997. Opportunities and Limitations for Image-Based Remote Sensing in Precision Crop Management. *Remote Sensing of Environment* [online]. 61(3), str. 319-346. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S003442579700045X>

Mulla, J. D., 2013. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering* [online]. 114(4), str. 358-371 [cit. 23. 8. 2018]. Dostupné z: <https://experts.umn.edu/en/publications/twenty-five-years-of-remote-sensing-in-precision-agriculture-key->

MZe, 2015. Závazný metodický postup k aktualizaci evidence půdy a ekologicky významných prvků [online]. [cit. 7. 9. 2018]. Dostupné z: http://eagri.cz/public/web/file/426857/met_ep_ev_090216.pdf

Pal, M., Mather, M. P., 2005. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing* [online]. 5, str. 1007-1011 [cit. 13. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/263448108_Support_vector_machines_for_classification_in_remote_sensing

Pan, Z. et al, 2015. Mapping crop phenology using NDVI time-series derived from HJ-1A/B data. *International Journal of Applied Earth Observation and Geoinformation* [online]. 34, str. 188-197 [cit. 28. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243414001755>

Psomiadis, E. et al., 2017. Evaluation and cross-comparison of vegetation indices for crop monitoring from sentinel-2 and worldview-2 images. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XIX* [online]. 10421 [cit. 21. 8. 2018]. Dostupné z:

https://www.researchgate.net/publication/320481545_Evaluation_and_cross-comparison_of_vegetation_indices_for_crop_monitoring_from_sentinel-2_and_worldview-2_images

Planet, 2018. PLANET IMAGERY AND ARCHIVE [online]. [cit. 15. 9. 2018]. Dostupné z: <https://www.planet.com/products/planet-imagery/>

Satellite Imaging Corporation, 2017. Sentinel-2A Satellite Sensor (10m) [online]. [cit. 15. 9. 2018]. Dostupné z: <https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/>

Sera, B., Hajkova, L., 2014. Fenologické fáze zemědělských plodin ve vztahu k vědecko-výzkumné činnosti. *Příspěvky k problematice zemědělského pokusnictví* [online]. str. 63-69 [cit. 27. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/282015020_Fenologicke_faze_zemedelskych_plodin_ve_vztahu_k_vedecko-vyzkumne_cinnosti

Schowengerdt, A. R., 2007. Remote Sensing: Models and methods for image processing. 3. vyd. Tuscon: University of Arizona. 515 str. ISBN 10: 0-12-369407-8.

Smola, J. A., Schölkopf, B., 2004. A Tutorial on Support Vector Regression. *Statistics and Computing* [online]. 14(3), str. 199-222 [cit. 13. 8. 2018]. Dostupné z: <http://scikit-learn.org/stable/modules/svm.html#classification>

Sola, I. et al., 2018. Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes. *International Journal of Applied Earth Observation and Geoinformation* [online]. 73, str. 63-76. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243418301843>

Song, C. et al., 2004. Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects?. *Remote Sensing of Environment* [online]. 75(2), str. 230-244 [cit. 19. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0034425700001693>

Sonobe, R. et al., 2018. Crop classification from Sentinel-2 derived vegetation indices using ensemble learning. *J. of Applied Remote Sensing* [online]. 12(2) [cit. 21. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/325228631_Crop_classification_from_Sentinel-2-derived_vegetation_indices_using_ensemble_learning

Steven, D. M., Clark, A. J., 1990. Application of Remote Sensing in Agriculture. Nottingham: University of Nottingham. 440 str. ISBN 978-0-408-04767-8.

Ustuner, M. et al., 2014. CROP TYPE CLASSIFICATION USING VEGETATION INDICES OF RAPIDEYE IMAGERY. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. XL-7 [cit. 21. 8. 2018]. Dostupné z: https://www.researchgate.net/publication/266030489_Crop_Type_Classification_Using_Vegetation_Indices_of_RapidEye_Imagery

Vapnik, V., 1995. The Nature of Statistical Learning Theory. New York: Springer-Verlag New York. 2. vyd. 314 str. ISBN 978-0-387-98780-4.

Vaudour, E. et al., 2015. Early-season mapping of crops and cultural operations using very high spatial resolution Pléiades images. *International Journal of Applied Earth Observation and Geoinformation* [online]. 42, str. 128-141 [cit. 21. 8. 2017]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243415001324>

Vrieling, A. et al, 2018. Vegetation phenology from Sentinel-2 and field cameras for a Dutch barrier island. *Remote Sensing of Environment* [online]. 215, str. 517-529 [cit. 23. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S003442571830107X>

Vuolo, F. et al., 2018. How much does multi-temporal Sentinel-2 data improve crop type classification?. *International Journal of Applied Earth Observation and Geoinformation* [online]. 72, str. 122-130. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243418303167>

Waldhoff, G., Lussem, U., Bareth, G., 2017. Multi-Data Approach for remote sensing-based regional crop rotation mapping: A case study for the Rur catchment, Germany. *Int J Appl Earth Obs Geoinformation* [online]. 61, str. 55-69 [cit. 28. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243417300934>

Zheng, B. et al., 2015. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *International Journal of Applied Earth Observation and Geoinformation* [online]. 34. Str. 103-112 [cit. 27. 8. 2018]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0303243414001615>

POUŽITÉ DATOVÉ ZDROJE

ARCDATA PRAHA, 2016. ArcČR 500: Digitální geografická databáze 1 : 500 000. Verze 3.3. Praha. [cit. 2016–10–01]. Dostupné z: <https://www.arcdata.cz/produkty/geograficka-data/arccr-500>

ČÚZK, 2011. Základní mapa ČR. [webová mapová služba ArcGis online]. [1:10 000]. [cit. 7. 9. 2018]. Dostupné z: <http://geoportal.gov.cz/web/guest/map>

ČÚZK, 2016. Prohlížeč služba WMTS - Ortofoto ČR [digitální data ESRI Shapefile]. [1:10 000]. [cit. 20. 3. 2014]. Dostupné z: <http://geoportal.cuzk.cz/geoprohlizec/?wmcid=693>

ESA, 2017. Sentinel-2: Satellite images.

1. 1. 2017: S2A_MSIL2A_20170101T100412_N0204_R122_T33UWR_20170101T100407.SAFE,
1. 4. 2017: S2A_MSIL2A_20170401T100021_N0204_R122_T33UWR_20170401T100022.SAFE,
11. 5. 2017: S2A_MSIL2A_20170511T100031_N0205_R122_T33UWR_20170511T100539.SAFE,
3. 6. 2017: S2A_MSIL2A_20170603T101031_N0205_R022_T33UWR_20170603T101026.SAFE,
20. 6. 2017: S2A_MSIL2A_20170620T100031_N0205_R122_T33UWR_20170620T100453.SAFE,
7. 8. 2017: S2B_MSIL2A_20170807T101029_N0205_R022_T33UWR_20170807T101349.SAFE.
29. 8. 2017: S2A_MSIL2A_20170829T100031_N0205_R122_T33UWR_20170829T100026.SAFE
28. 9. 2017: S2A_MSIL2A_20170928T100021_N0205_R122_T33UWR_20170928T100617.SAFE,
1. 10. 2017: S2A_MSIL2A_20171001T101021_N0205_R022_T33UWR_20171001T101350.SAFE,
16. 10. 2017: S2B_MSIL2A_20171016T101009_N0205_R022_T33UWR_20171016T101010.SAFE.
7. 12. 2017: S2A_MSIL2A_20171207T100401_N0206_R122_T33UWR_20171207T120506.SAFE.
Dostupné z: <https://scihub.copernicus.eu/dhus/>

PLANET, 2017. PlanetScope: Satellite images.

1. 4. 2017: 20170401_091310_0e20, 20170401_091309_0e20, 20170401_091308_0e20,
20170401_091307_0e20,
11. 5. 2017: 20170511_090838_1009, 20170511_090837_1009, 20170511_090836_1009,
18. 5. 2017: 20170518_091518_0e0f, 20170518_091517_0e0f, 20170518_091516_0e0f,
20170518_091515_0e0f,
3. 6. 2017: 20170603_090957_0f28, 20170603_090956_0f28, 20170603_090955_0f28,
20170603_090954_0f28,
15. 6. 2017: 20170615_091040_1036, 20170615_091039_1036, 20170615_091038_1036,
20170615_090910_1039, 20170615_090911_1039,
19. 6. 2017: 20170619_091017_100e, 20170619_091016_100e, 20170619_091015_100e,
20170619_091014_100e,
20. 6. 2017: 20170620_091108_1031, 20170620_091107_1031, 20170620_091106_1031,
20170620_091105_1031,
22. 6. 2017: 20170622_091057_0f3f, 20170622_091056_0f3f, 20170622_091055_0f3f,
20170622_090955_1022, 20170622_090954_1022, 20170622_090953_1022,
31. 7. 2017: 20170731_091233_1036, 20170731_091233_1036, 20170731_091230_1036,
20170731_091229_1036, 20170731_091017_1039, 20170731_091016_1039,
20170731_091015_1039, 20170731_091014_1039,
1. 8. 2017: 20170801_091316_1006, 20170801_091315_1006, 20170801_091314_1006,
20170801_091252_102e, 20170801_091251_102e, 20170801_091250_102e,
20170801_091249_102e,
5. 8. 2017: 20170805_091225_1031, 20170805_091224_1031, 20170805_091223_1031,
20170805_091222_1031,
10. 8. 2017: 20170810_091433_1044, 20170810_091432_1044, 20170810_091431_1044,
29. 8. 2017: 20170829_091514_103c, 20170829_091513_103c, 20170829_091512_103c,
20170829_091511_103c,
30. 8. 2017: 20170830_091529_0f22, 20170830_091528_0f22, 20170830_091527_0f22,
20170830_091526_0f22, 20170830_091613_1032, 20170830_091612_1032,
20170830_091611_1032, 20170830_091610_1032,
28. 9. 2017: 20170928_091145_1024, 20170928_091144_1024, 20170928_091143_1024,
20170928_091142_1024,
29. 9. 2017: 20170929_091643_0e0e, 20170929_091642_0e0e, 20170929_091641_0e0e,
20170929_091640_0e0e,
14. 10. 2017: 20171014_091654_1022, 20171014_091653_1022, 20171014_091652_1022,
20171014_091641_0f12, 20171014_091640_0f12, 20171014_091639_0f12, 20171014_091638_0f12,

15. 10. 2017: 20171015_091605_1001, 20171015_091604_1001, 20171015_091603_1001, 20171015_091602_1001,
16. 10. 2017: 20171016_091556_1036, 20171016_091555_1036, 20171016_091554_1036, 20171016_091553_1036,
17. 10. 2017: 20171017_091757_1040, 20171017_091756_1040, 20171017_091755_1040, 20171017_091754_1040,
7. 12. 2017: 20171207_091802_0f18, 20171207_091801_0f18, 20171207_091800_0f18, 20171207_091859_0f18.

Dostupné z: <https://www.planet.com/explorer/>

SZIF, 2017a. Půdní bloky v okrese Kolín: 20170513-3204-DPB-SHP.zip. Dostupné z: <http://eagri.cz/public/app/eagriapp/lpisdata/>

SZIF, 2017b. Půdní bloky v okrese Kutná Hora: 20170513-3205-DPB-SHP.zip. Dostupné z: <http://eagri.cz/public/app/eagriapp/lpisdata/>

SZIF, 2017c. Data o plodinách v okresech Kolín a Kutná Hora od soukromých subjektů z databáze LPIS

SEZNAM PŘÍLOH

Tab. 24: Přehled všech provedených klasifikací dle celkové přesnosti

dataset	pixelová klasifikace		objektová klasifikace					
	ML	SVM radial basis	KNN	PCA	SVM linear	SVM polynomial	SVM radia basis	SVM sigmoid
dataset	celková přesnost (%)							
1. multitemporální dataset S-2	88,40	83,59	80,55	30,23	85,96	86,04	86,98	33,00
1.4.2017	56,71	-	-	-	-	-	-	-
11.5.2017	71,72	-	-	-	-	-	-	-
3.6.2017	75,66	-	-	-	-	-	-	-
20.6.2017	76,19	-	-	-	-	-	-	-
7.8.2017	53,24	-	-	-	-	-	-	-
29.8.2017	44,13	-	-	-	-	-	-	-
2. multitemporální dataset S-2	86,30	82,78	79,18	12,34	86,65	85,67	87,29	79,15
1.4.2017	42,28	-	-	-	-	-	-	-
11.5.2017	63,35	-	-	-	-	-	-	-
3.6.2017	71,51	-	-	-	-	-	-	-
20.6.2017	50,87	-	-	-	-	-	-	-
7.8.2017	53,24	-	-	-	-	-	-	-
29.8.2017	38,34	-	-	-	-	-	-	-
multitemporální dataset PS	84,85	-	74,15	43,88	83,07	85,29	84,76	75,38
11.5.2017	59,42	-	-	-	-	-	-	-
3.6.2017	67,13	-	-	-	-	-	-	-
15.6.2017	59,08	-	-	-	-	-	-	-
22.6.2017	48,33	-	-	-	-	-	-	-
31.7.2017	54,14	-	-	-	-	-	-	-
1.8.2017	45,16	-	-	-	-	-	-	-
30.8.2017	36,93	-	-	-	-	-	-	-
NDVI dataset S-2	70,53	-	-	-	-	-	-	-
NDVI dataset PS	65,01	-	-	-	-	-	-	-
PCA dataset S-2	68,81	-	-	-	-	-	-	-
PCA dataset PS	62,68	-	-	-	-	-	-	-

Tab. 25: Porovnání všech klasifikací monotemporálního přístupu pro data S-2

datum	01.04.2017		11.05.2017		03.06.2017		20.06.2017		07.08.2017		29.08.2017	
třída	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)
cukrovka	67,48	39,35	73,59	36,98	83,54	82,13	79,34	95,87	74,79	98,08	77,57	98,11
ječmen jarní	50,97	42,24	49,19	85,01	69,95	77,23	71,58	67,60	9,03	17,09	15,64	8,44
ječmen ozimý	85,33	17,96	82,63	23,18	76,78	34,23	95,37	47,17	63,48	11,78	36,27	5,67
kukuřice	29,58	47,51	44,36	63,88	74,42	89,60	85,64	95,09	84,43	99,82	88,60	99,77
ostatní	8,72	8,59	31,02	29,36	55,57	33,77	53,74	40,42	47,07	35,82	37,35	39,25
pšenice jarní	20,04	5,06	42,64	15,54	31,54	9,06	38,90	8,06	45,10	4,13	29,65	3,00
pšenice ozimá	52,10	89,02	78,71	96,03	74,66	94,61	68,80	94,01	38,91	79,71	20,56	72,24
řepka ozimá	90,52	88,73	96,62	99,04	91,49	99,24	89,57	74,69	62,30	84,06	56,54	67,59
trávy	92,19	63,29	86,84	72,35	77,64	76,32	92,95	99,38	87,02	64,65	80,31	62,29

Tab. 28: Porovnání celkových přesností monotemporálních klasifikací

datum	celková přesnost (%) multitemporálních datasetů		
	Sentinel-2 (1.)	Sentinel-2 (2.)	PlanetScope
01.04.2017	56,71	42,28	x
11.05.2017	71,72	63,35	59,42
03.06.2017	75,66	71,51	67,13
15.06.2017	x	x	59,08
20.06.2017	76,19	50,87	x
22.06.2017	x	x	48,33
31.07.2017	x	x	54,14
01.08.2017	x	x	45,16
07.08.2017	53,24	53,24	x
29.08.2017	44,13	38,34	x
30.08.2017	x	x	36,93

Tab. 27: Porovnání pixelové klasifikace 2. multitemporálního datasetu S-2 a multitemporálního datasetu PS

2. multitemporální dataset Sentinel-2					multitemporální dataset PlanetScope			
CP = (528904/612858) 86.3012%					CP = (4554183/5367054) 84.8544%			
Kappa koeficient = 0.8269					Kappa Coefficient = 0.8108			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	81,19	98,26	1,74	18,81	76,17	98,02	1,98	23,83
ječmen jarní	69,56	96,17	3,83	30,44	66,50	90,50	9,50	33,50
ječmen ozimý	87,77	87,96	12,04	12,23	97,84	60,74	39,26	2,16
kukuřice	86,47	99,56	0,44	13,53	92,66	98,14	1,86	7,34
ostatní	69,34	43,46	56,54	30,66	79,32	48,85	51,15	20,68
pšenice jarní	43,76	29,69	70,31	56,24	28,34	14,64	85,36	71,66
pšenice ozimá	90,39	95,51	4,49	9,61	85,98	95,28	4,72	14,02
řepka ozimá	96,24	99,37	0,63	3,76	94,80	99,32	0,68	5,20
trávy	88,43	78,86	21,14	11,57	84,17	85,49	14,51	15,83

Tab. 26: Porovnání celkových přesností objektové klasifikace obou multitemporálních datasetů S-2

1. multitemporální dataset Sentinel-2					2. multitemporální dataset Sentinel-2			
CP = (481616/553679) 86,9847%					CP = (483327/553679) 87,2937%			
Kappa koeficient = 0,8359					Kappa koeficient = 0,8383			
třída	ZP (%)	UP (%)	CHZ (%)	CHO (%)	ZP (%)	UP (%)	CHZ (%)	CHO (%)
cukrovka	95,98	98,22	1,78	4,02	95,97	82,68	17,32	4,03
ječmen jarní	74,78	95,59	4,41	25,22	80,39	89,86	10,14	19,61
ječmen ozimý	96,66	54,13	45,87	3,34	96,23	56,73	43,27	3,77
kukuřice	94,49	96,80	3,20	5,51	83,65	95,81	4,19	16,35
ostatní	62,10	72,64	27,36	37,90	52,69	66,49	33,51	47,31
pšenice jarní	44,68	11,43	88,57	55,32	33,28	14,80	85,20	66,72
pšenice ozimá	86,98	95,35	4,65	13,02	92,38	96,27	3,73	7,62
řepka ozimá	96,75	97,33	2,67	3,25	96,60	94,93	5,07	3,40
trávy	93,25	90,95	9,05	6,75	95,06	81,19	18,81	4,94
klasifikační metoda		1. md. Sentinel-2		2. md. Sentinel-2				
		celková přesnost (%)						
KNN		80,55		79,18				
PCA		30,23		12,34				
SVM linear		85,96		86,65				
SVM polynomial		86,04		85,67				
SVM sigmoid		33,00		79,15				
SVM radial basis		86,98		87,29				